

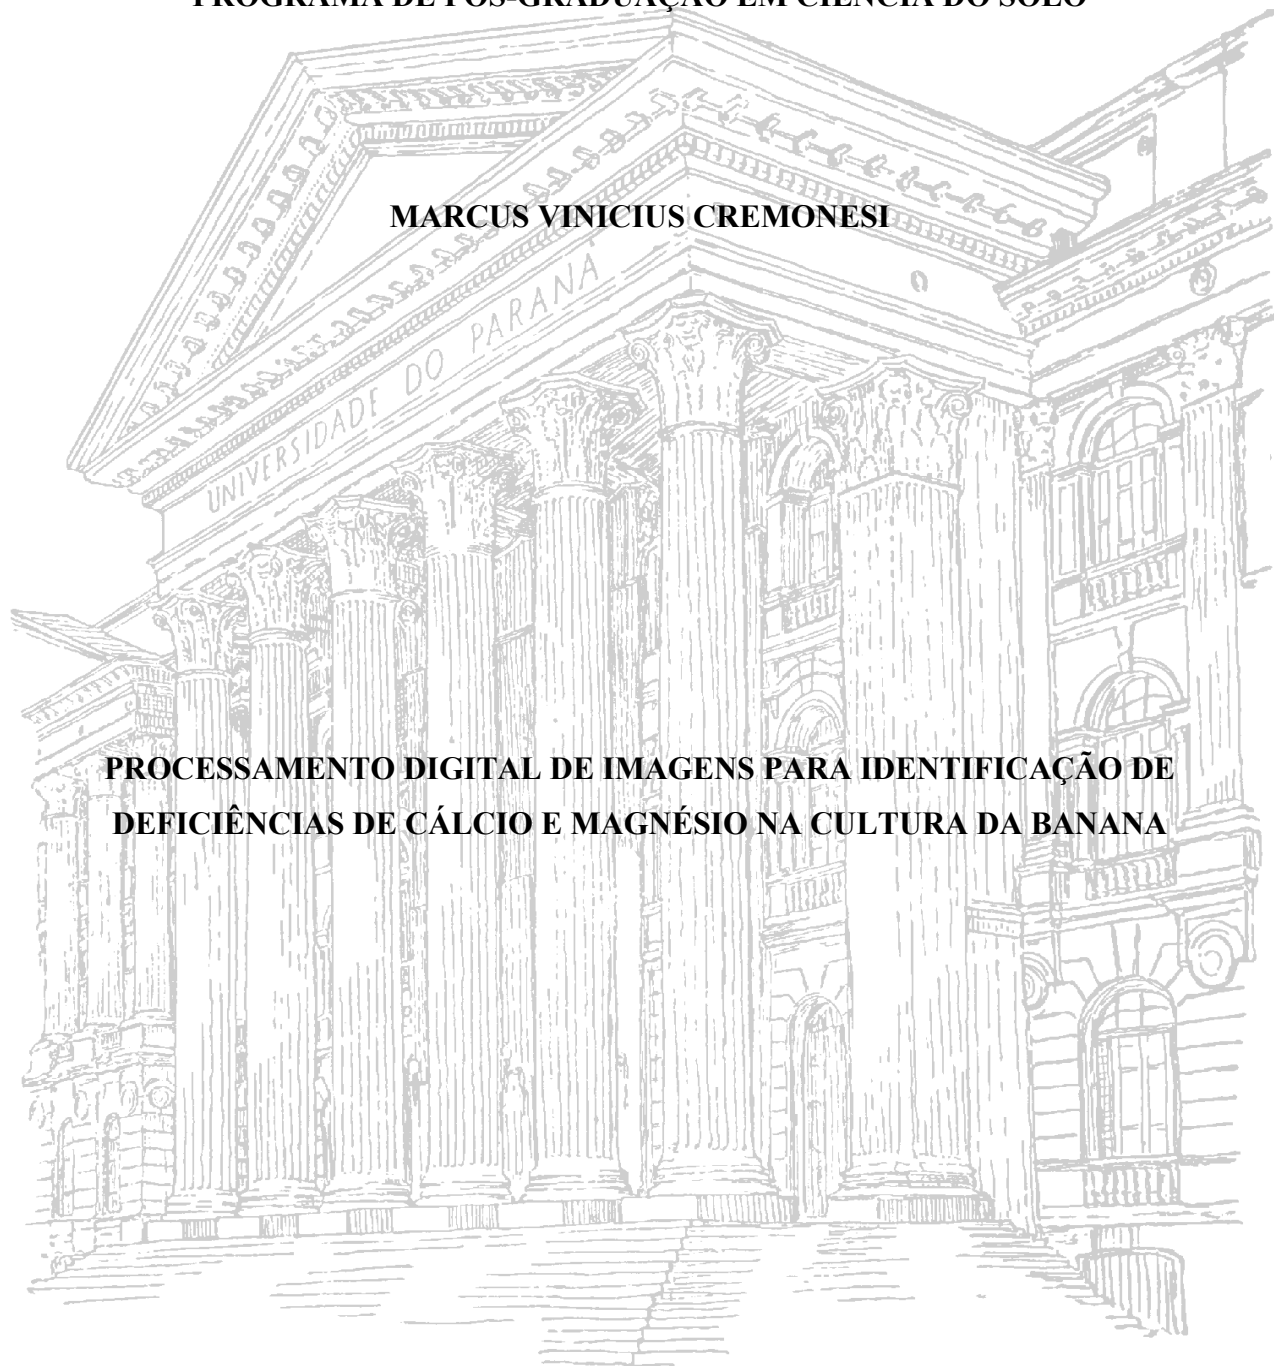
**UNIVERSIDADE FEDERAL DO PARANÁ  
SETOR DE CIÊNCIAS AGRÁRIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DO SOLO**

**MARCUS VINICIUS CREMONESI**

**PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE  
DEFICIÊNCIAS DE CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA**

**CURITIBA**

**2016**



**UNIVERSIDADE FEDERAL DO PARANÁ**  
**SETOR DE CIÊNCIAS AGRÁRIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DO SOLO**

**MARCUS VINICIUS CREMONESI**

**PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE  
DEFICIÊNCIAS CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência do Solo, Área de Concentração Solo e Ambiente, do Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Mestre em Ciência do Solo.

Orientador: Prof. Dr. Danilo Eduardo Rozane

Co-orientador: Prof. Dr. Volnei Pauletti

Co-orientadora: Prof. Dra. Silvia Helena  
Modenese Gorla da Silva

**CURITIBA**

**2016**

C915 Cremonesi, Marcus Vinicius

Processamento digital de imagens para identificação de deficiências de cálcio e magnésio na cultura da banana.

Marcus Vinicius Cremonesi. / Curitiba: 2016.

76 f. il.

Orientador: Danilo Eduardo Rozane

Dissertação (Mestrado) – Universidade Federal do Paraná. Setor de Ciências Agrárias. Programa de Pós-Graduação em Ciência do Solo.

1. Banana - Cultivo. 2. Banana – Adubos e fertilizantes. 3. Processamento de imagens – Técnicas digitais. I. Rozane, Danilo Eduardo. II. Universidade Federal do Paraná. Setor de Ciências Agrárias. Programa de Pós-Graduação em Ciência do Solo. III. Título.

CDU 634.771:528.78



## PARECER

A Banca Examinadora designada para avaliar a defesa da Dissertação de Mestrado de **Marcus Vinicius Cremonesi**, intitulada: **"Processamento digital de imagens para identificação de deficiências de cálcio e magnésio na cultura da banana"**, do Programa de Pós-Graduação em Ciência do Solo do Setor de Ciências Agrárias da Universidade Federal do Paraná, após análise do texto e arguição do candidato, emitem parecer pela **"APROVAÇÃO"** da referida Dissertação. O candidato atende assim um dos requisitos para a obtenção do título de **Mestre em Ciência do Solo - Área de Concentração Solo e Ambiente**.

Secretaria do Programa de Pós-Graduação em Ciência do Solo, em Curitiba, 26 de fevereiro de 2016.

  
Prof. Dr. Danilo Eduardo Rozane, Presidente

  
Prof. Dra. Silvia Helena Modenese Gorla da Silva, Iº. Examinador

  
Prof. Dr. Volnei Pauletti, IIº. Examinador

Aos meus pais, Antonia Aparecida Sousa da Silva e Edgard Cremonesi e minha tia  
Adalgisa de Sousa Silva, maiores incentivadores da minha caminhada.

## **AGRADECIMENTOS**

Ao Universo, pela oportunidade de estarmos aqui hoje.

À minha família, companheiro e amigos que me acompanharam nesta trajetória.

À Universidade Federal do Paraná – UFPR por meio do Programa de Pós Graduação em Ciência do Solo, pela oportunidade de realização do curso de mestrado.

À Universidade Estadual Paulista “Júlio de Mesquita Filho” - UNESP campus de Registro, pela concessão da área para realização do experimento.

À CAPES pela concessão da bolsa de estudos que permitiu a realização deste projeto.

Aos meus orientadores Professor Dr. Danilo Eduardo Rozane, Professor Dr. Volnei Pauletti e a Professora Dra. Silvia Helena Modenese Gorla da Silva pela orientação, dedicação, disponibilidade e, sobretudo paciência, exemplo e experiência.

Aos amigos Bruno Vizioli, Priscila Golfetto, Emanuelle Reztlaff, Felipe Y. Abboud, Bruna Ramalho, Sisara R. Oliveira e Karla R. Piekarski pela alegria compartilhada.

À Professora Dra. Silvia Helena Modenese Gorla da Silva por todos estes anos de orientação.

Aos funcionários e colegas que participaram da execução deste projeto.

Aos colegas dos cursos de mestrado e doutorado do Programa de Pós Graduação em Ciência do Solo da UFPR pela amizade, convívio e aprendizado.

“Gracias a la vida que me ha dado tanto  
Me dio dos luceros que cuando los abro  
Perfecto distingo lo negro del blanco  
Y en el alto cielo su fondo estrellado  
Y en las multitudes el hombre que yo amo.

(...)

Gracias a la vida que me ha dado tanto  
Me ha dado la marcha de mis pies cansados  
Con ellos anduve ciudades y charcos,  
Playas y desiertos montañas y llanos  
Y la casa tuya, tu calle y tu patio.

Gracias a la vida que me ha dado tanto  
Me dio el corazón que agita su marco  
Cuando miro el fruto del cerebro humano,  
Cuando miro al bueno tan lejos del malo,  
Cuando miro al fondo de tus ojos claros.

Gracias a la vida que me ha dado tanto  
Me ha dado la risa y me ha dado el llanto,  
Así yo distingo dicha de quebranto  
Los dos materiales que forman mi canto  
Y el canto de ustedes que es el mismo canto  
Y el canto de todos que es mi propio canto.  
Gracias a la vida”

Violeta Parra.

## SUMÁRIO

RESUMO GERAL.....	viii
GENERAL ABSTRACT.....	x
INTRODUÇÃO GERAL.....	1
CAPÍTULO 1. PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE DEFICIÊNCIAS DE CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA EM CASA DE VEGETAÇÃO.....	9
RESUMO.....	9
ABSTRACT.....	10
1.1. INTRODUÇÃO.....	11
1.2. MATERIAL E MÉTODOS.....	12
1.3. RESULTADOS E DISCUSSÃO.....	16
1.4. CONCLUSÕES.....	35
1.5. LITERATURA CITADA.....	36
CAPÍTULO 2. VALIDAÇÃO DE CAMPO DO PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE DEFICIÊNCIAS DE CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA.....	42
RESUMO.....	42
ABSTRACT.....	43
2.1. INTRODUÇÃO.....	44
2.2. MATERIAL E MÉTODOS.....	45
2.3. RESULTADOS E DISCUSSÃO.....	49
2.4. CONCLUSÕES.....	58
2.5. LITERATURA CITADA.....	58
CONCLUSÃO GERAL.....	63
CONSIDERAÇÕES FINAIS.....	64
REFERÊNCIAS GERAIS.....	66



# **PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE DEFICIÊNCIAS DE CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA <sup>1</sup>**

Autor: Marcus Vinicius Cremonesi

Orientador: Prof. Dr. Danilo Eduardo Rozane

Co-Orientador: Prof. Dr. Volnei Pauletti

Co-orientadora: Profª. Dra. Silvia Helena Modenese Gorla da Silva

## **RESUMO GERAL**

O Brasil é o 4º país em produção de bananas do mundo (FAO, 2014), sendo uma cultura altamente exigente em nutrientes para sustentação de copa e frutos. Os elementos cálcio e magnésio são essenciais à bananeira e sua aplicação se dá via calcário. A calagem mal executada ou negligenciada pode acarretar na deficiência destes elementos na planta, sendo de difícil identificação, quando ocorrendo em conjunto, e remediação no mesmo ciclo produtivo, acarretando perdas em produtividade. A identificação correta e precoce de deficiências nutricionais pode ser feita a partir de imagens digitais analisadas por ferramentas computacionais com capacidade de notar pequenas e características mudanças de coloração das folhas, muito antes de serem notadas por olhos humanos. Em função disto, foi realizada uma sequência de experimentos em casa de vegetação com cinco épocas de coleta e cinco variações nutricionais visando gerar uma base de dados com as características das deficiências de cálcio, magnésio e ambos conjuntamente a partir de imagens das folhas. Para a análise da base de dados e seleção dos parâmetros de classificação foi utilizada a técnica de redes neurais artificiais, o classificador obteve precisão de 90 % para omissão de cálcio, 73,3 % para omissão de magnésio, 96,7 % para omissão de cálcio e magnésio, 88,3 % para solução nutritiva completa e 96,7 % para cultivo em solo, após seleção dos atributos nas melhores épocas de coleta, com melhora de 29% na média. Após os resultados, foi conduzido um experimento a campo, em local com baixa concentração de nutrientes no solo, com cinco doses de calcário, variando de 0 a 13,82 t ha<sup>-1</sup>. Foi verificado se os classificadores gerados seriam capazes de identificar deficiências nutricionais de cálcio e magnésio a partir das folhas dos tratamentos de campo com o aprendizado obtido pela base de dados gerada em casa de

---

<sup>1</sup> Dissertação de Mestrado em Ciência do Solo. Programa de Pós-Graduação em Ciência do Solo, Setor de Ciências Agrárias, Universidade Federal do Paraná. Curitiba. (65 p.) Fevereiro, 2016.

vegetação. O classificador demonstrou que os tratamentos com menores doses de calcário se enquadraram na classe omissão de cálcio e magnésio (-Ca/Mg) e a medida que as doses cresceram os tratamentos migraram para a classe correspondente a solução nutritiva completa (Comp.) obtida em casa de vegetação.

Palavras-chave: PDI. Redes neurais artificiais. Nutrição da bananeira. Deficiência de cálcio. Deficiência de magnésio.

# **DIGITAL IMAGES PROCESSING FOR IDENTIFICATION OF CALCIUM AND MAGNESIUM DEFICIENCIES IN BANANA CROPS <sup>2</sup>**

Author: Marcus Vinicius Cremonesi

Advisor: Prof. Dr. Danilo Eduardo Rozane

Co- Advisor: Prof. Dr. Volnei Paletti

Co- Advisor: Profa. Dra. Silvia Helene Modenese Gorla da Silva

## **GENERAL ABSTRACT**

Brazil is 4<sup>th</sup> country in the world of bananas production (FAO, 2012), it is extremely exigent in nutrition culture to maintain leafs and fruits. The calcium and magnesium elements are essentials to banana's plants and his applications are made by limestone. The poorly executed or neglected liming may result in deficient of those elements on plant, it is difficult to identify, when occurring together, and to remedy in the same production cycle, taking to yield losses. The premature and correct identification of nutritional deficiencies can be done using digital images analyses by computational tools with capacity to identify little and particulars color changes in leafs, long before human eyes. Due to this, was made a sequence of experiments on a greenhouse with five collection times and five nutritional variations aimed at generating a deficient characteristic database of calcium, magnesium and both with leafs images. For the database analysis and selection of classification parameters were used the Artificial Neural Networks (ANN), the classifier obtained 90 % of precision to identify calcium's omission, 73.3 % of magnesium's omission, 96.7 % of calcium and magnesium's omission, 88.3% of complete nutrient solution and 96.7 % of soil cultivation, after selection of attributes in the best collect times, with 29 % improvement in man. After those results, was leading a field experiment, in low nutrient's concentration area, with five limestone doses, ranging from 0 to 13.82 t ha<sup>-1</sup>. Was checked the capacity of generated classifiers to identify nutritional deficient of calcium and magnesium from leafs of field treatments with the learning obtained by greenhouse database. The classifier manifested that the treatments of lower limestone doses were framed in calcium and magnesium omission class (-Ca/Mg), and

---

<sup>2</sup> Soil Science Master Dissertation. Programa de Pós-Graduação em Ciência do Solo, Setor de Ciências Agrárias, Universidade Federal do Paraná. Curitiba. (65 p.) February, 2016.

as the limestone doses increases the treatments were fits in complete nutritional solution class (Comp.)

Key-Words: DIP. Artificial Neural Networks. Banana nutrition. Calcium deficiente. Magnesium deficient.

## INTRODUÇÃO GERAL

Na fruticultura mundial a banana tem se estabelecido como a segunda maior frutífera cultivada, sendo cultivada em mais de 125 países. O continente asiático lidera a produção com 58 % do volume produzido, seguido pelo americano com 26 % (América do Sul, com 17 % e a América Central com 8 %), e o africano com 14 % (FAO, 2014). No Brasil, o quarto maior produtor mundial desta frutífera, as produções anuais equivalem a 6,9% da produção mundial, superando sete milhões de toneladas, perdendo em volume apenas para a citricultura (FAO, 2016).

A bananicultura está presente de Norte a Sul do país já a alguns séculos (Schmidt, 1934), e suas práticas de cultivo sofreram, desde então, profundas modificações (Alves, 1999; Moraes et al., 2006, Gonçalves e Perez, 2013). Mesmo enquadrando-se entre os maiores produtores mundiais, observando o período das safras agrícolas de 2009 a 2013, o Brasil apresentou o rendimento médio de 14,3 t ha<sup>-1</sup> (ou, 12,0 t ha<sup>-1</sup> segundo Agrianual, 2016), ou seja, inferior à média mundial que é de 19,3 t ha<sup>-1</sup>. O maior rendimento médio por área colhida pertence à Nicarágua, que perfaz 55,6 t ha<sup>-1</sup> (FAO, 2014).

No Brasil, os melhores rendimentos na safra 2015 pertencem ao Rio Grande do Norte. Embora não tenha uma produção tão expressiva (158 mil toneladas – 10º posição no ranking nacional), atinge mais que o dobro da média nacional, com 30 t ha<sup>-1</sup>. Praticamente empatados na segunda posição estão Paraná e Santa Catarina, com 24 t ha<sup>-1</sup>, seguidos por São Paulo, com o quarto melhor desempenho, produzindo 21 t ha<sup>-1</sup>, apesar de ser o maior estado produtor com 1,13 milhões de toneladas produzidas (Agrianual, 2016).

A banana é a segunda fruta mais consumida no planeta, com 11,4 kg hab<sup>-1</sup> ano<sup>-1</sup>, perdendo apenas para a laranja, com 12,2 kg hab<sup>-1</sup> ano<sup>-1</sup>. O continente americano é o maior consumidor, com 15,2 kg hab<sup>-1</sup> ano<sup>-1</sup>, destacando-se a América do Sul, com 20 kg hab<sup>-1</sup> ano<sup>-1</sup> e a América Central, com 13,9 kg hab<sup>-1</sup> ano<sup>-1</sup> (FAO, 2014). O mercado interno brasileiro consome praticamente a totalidade da produção de banana do país, em torno de 7,3 milhões de t ano<sup>-1</sup>, com as regiões Sul e Sudeste respondendo por aproximadamente 45% das áreas de cultivo (IBGE, 2013; Gonçalves e Perez, 2013; FAO, 2014).

A fruticultura, e em especial a Bananicultura é responsável pela fixação do homem no campo, sendo implantada como cultura de subsistência, na agricultura familiar, agroflorestas e por empresários agrícolas da cadeia. É utilizada como base alimentar ou acompanhante da alimentação diária de bilhões de pessoas, possuindo um baixo valor calórico e altos teores de potássio, vitamina A, fósforo, manganês, entre outros (Yuyama et al., 2000).

Originária da África e Ásia, a banana se adaptou muito bem às condições climáticas tropicais e subtropicais das Américas, o que faz a produção ser distribuída durante todo o ano, atendendo de forma regular as necessidades de consumo, com participação de praticamente todos os estados brasileiros (Vieira, 2013).

Em quantidades acumuladas, a bananeira possui sua maior exigência nos macronutrientes potássio (K) e nitrogênio (N), seguidos pelo cálcio (Ca), magnésio (Mg), fósforo (P) e enxofre (S) (Lopez e Espinosa, 1995; Borges et al., 2002; Raij, 2011).

O Ca atua principalmente como constituinte da lamela média, paredes e membranas das células e também participa da divisão celular entre outras funções (Halkesford, 2012). Os maiores teores são encontrados nas folhas, pecíolo e pseudocaule durante o ciclo vegetativo e durante crescimento dos frutos (Gomes et al., 1988). A ausência da quantidade adequada de Ca provoca aumento da espessura das nervuras secundárias, deformação do limbo foliar, seguido por clorose nas extremidades e necrose a partir do ápice das folhas novas (Martin-Prével, 1980; Delvaux, 1995).

O Mg, por sua vez, participa em diversos processos de geração de energia junto ao N como constituinte da clorofila, é o responsável pela síntese e ativação de diversas enzimas, caracterizando clorose marginal que avança entre as nervuras nas folhas velhas quando em falta ou desbalanceado na planta (Gomes et al., 1988; Maathuis, 2009). O Mg age também como transportador do P (Vitti et al., 2006) e potencializa os efeitos do K quando em teores adequados (Silva et al., 1999).

Todo elemento considerado atualmente como nutriente possui funções e especificidade de atuação definidos (Malavolta, 2006), contudo, a interação na manifestação da sintomatologia de deficiências é comumente observada, a exemplo da deficiência de Ca e Mg que inúmeras vezes está associada à carência na aplicação de calcário (Venturini et al., 2000).

A interação desta sintomatologia causa uma desordem generalizada na planta por tratar-se de elementos com funções e mobilidades distintas que alteram a resposta da cultura em crescimento e produção (Gomes et al., 2002), sendo observada a deformação, seca e morte da região apical em direção à região basal em conjunto com clorose nas margens das folhas basais em direção à nervura principal progredindo para a região apical da planta.

Deficiências de nutrientes resultam assim em disfunções fisiológicas que, em último estágio, são perceptíveis a olho nu, caracterizadas por mudança na forma e na coloração normal dos órgãos das plantas. Estas alterações, algumas vezes, são típicas e apresentam características próprias para cada elemento permitindo, assim, a diagnose visual por parte do

observador que, quando treinado, é capaz de inferir o nutriente deficitário (Epstein e Bloom, 2006; Malavolta, 1980). Se o diagnóstico for realizado precocemente, é possível realizar a intervenção ainda no mesmo ciclo de produção, como evidenciam Wu et al. (2007). No entanto, esta identificação é empírica e necessita de comprovação mediante análise de solo e/ou do tecido vegetal, o que demanda certo tempo.

Contudo, não necessariamente é preciso o observador presente no local, nem tão pouco do empirismo humano para identificar as deficiências nutricionais, pois estas podem ser observadas por meio de imagens adquiridas por meios distintos. Assim, imagens conterão informações da coloração e da posição onde a anomalia se encontra, bem como demonstrar o formato e as demais características da planta. Esta imagem é um registro de informações digitais, onde é possível extrair e trabalhar informações por meio do Processamento Digital de Imagens (PDI).

Por PDI, entende-se a *i)* aquisição de uma imagem digital por meios e/ou mecanismos diversos, *ii)* segmentação e reagrupamento de conjuntos semelhantes em categorias e a *iii)* análise, que resulta nas informações úteis de acordo com a aplicação previamente determinada (Marques Filho e Vieira Neto, 1999) (FIGURA 1).

Esta segmentação de dados e formação de conjuntos de informações permitem a classificação de determinado grupo de indivíduos heterogêneos em subgrupos que apresentem mesma característica (Haykin, 1999). Esta capacidade de classificar grupos baseados em características é o fundamento das Redes Neurais Artificiais (RNA).




FIGURA 1. Esquema das etapas do Processamento Digital de Imagens, adaptado de Marques Filho e Vieira Neto (1999).

RNA são modelos matemáticos que se assemelham às estruturas biológicas, com capacidade de aprendizado e generalização que buscam reproduzir o aprendizado humano, com base na classificação de grupos através de informações aprendidas ou não (Cybenko, 1996; Haykin, 1999). O aprendizado acontece por meio de algoritmos, que são sequências lógicas, finitas e não ambíguas de instruções, geralmente apresentadas na forma de fórmulas.

A nomenclatura desta técnica, idealizada por McCulloch e Pitts (1943), consiste na organização destes algoritmos que seguem uma sequência em paralelo, permitindo uma interligação entre eles, denominados de neurônios, gerando redes (FIGURA 2). O peso entre estas conexões pode ser alterado, o que gera o processo de *aprendizagem* (Kovacs, 1996; Braga et al., 2000).




FIGURA 2. Exemplo de Rede Neural Artificial de três camadas, com quatro entradas e duas saídas.

O avanço tecnológico e sua facilidade de acesso a novas informações e ferramentas vêm se tornando comum no meio agrícola nos últimos anos. O uso de novas tecnologias baseadas no processamento digital de imagens, inteligência artificial e modelos na tomada de decisão já são habituais na determinação do vigor de sementes e crescimento de plantas (Teixeira et al., 2006), identificação, seleção e classificação de qualidade de frutos com visão artificial (Chalibabhongse et al., 2006; Chan et al., 2007), classificação de grãos (Aguilera et al., 2007) e muitos outros.

Sena-Júnior et al. (2003) trabalhando com imagens de campo determinaram o ataque da lagarta do cartucho com o uso de RNA. Silva (2008) utilizando o PDI, aliado à RNA desenvolveu uma ferramenta de apoio à identificação Sigatoka Negra em bananais. Na nutrição de plantas Abrahão et al. (2013) definiu índices de teores foliares de N e clorofila a partir de imagens e refletância.

### Literatura Citada

Abrahão SA, Pinto FAC, Queiroz DM, Santos NT, Carneiros JES. Determination of nitrogen and chlorophyll levels in bean-plant leaves by using spectral vegetation bands and indices. Fortaleza: R. Ciênc. Agron. 2013; 44:464-4173.



Agrianual. Anuário da Agricultura Brasileira. Banana. São Paulo. FNP. p.161-168. 2016.

Aguilera JM, Cipriano A, Eraña M, Lillo I, Mery D, Soto A, Valdivieso C. Computer vision for quality control in latin american foodindustry: a case study. In: international conference on computervision: workshop on computer vision applications fordevelopingcountries; outubro 2007; Ríó de Janeiro: Institute of Electrical and Electronics Engineers. 2007. p1-11.

Alves EJA. Cultura da banana: aspectos técnicos, socioeconômicos e agroindustriais. 2. ed. Brasília: EMBRAPA-CNPMF; 1999.

Borges AL, Raij B, Magalhães AFJ, Bernardi ACC. Nutrição e adubação da bananeira irrigada. Cruz das Almas: Embrapa Mandioca e Fruticultura; 2002. (Circular Técnica, 48)

Braga AP, Carvalho ACPLF, Ludemir TB. Redes neurais artificiais: teoria e aplicações. Rio de Janeiro: LTC; 2000.

Chalidabhongse T, Yimyam P, Sirisomboon P. 2D/3D vision-based mango's feature extraction and sorting. In: international conference on control, automation, robotics and vision; setembro 2006; Singapore: School of Electrical and Electronic Engineering. 2006.

Chan LM, Tan R, Thio G. Design of visual-based color classification system. Kuala Lumpur: Journal for the Advancement of Science & Arts. 2007; 2:30-33.

Cybenko G. Neural networks in computational science and engineering. Comp. Sc. Eng. 1996; 3:36-42.

Delvaux B. Soils. In: Gowen S. ed. Bananas and plantains. London: Chapman & Hall; 1995. p.230-257.

Epstein E, Bloom AJ. Nutrição mineral de plantas: princípios e perspectivas. Londrina: Editora Planta; 2006.

FAO. Statistics Division. Food and Agriculture commodities production [internet]. Roma: Fao; 2014 [acesso em 06 de fev de 2016]. Disponível em: [http://faostat3.fao.org/browse/rankings/countries\\_by\\_commodity/S](http://faostat3.fao.org/browse/rankings/countries_by_commodity/S).

FAO. Statistics Division. Food and Agriculture commodities production [internet]. Roma: Fao; 2016 [acesso em 12 de fev de 2016]. Disponível em: <http://faostat3.fao.org/browse/Q/QC/E>

Gomes FT, Borges AC, Neves JCL, Fontes PCR. Influence of limestone rates with different calcium:magnesium ratios on shoot dry matter yield and mineral composition of alfalfa. *Pesq. Agrop. Bras.* 2002; 37:1779-1786.

Gomes JA. Absorção de nutrientes pela bananeira cv. Prata (*Musa* AAB, subgrupo prata) em diferentes estádios de desenvolvimento [dissertação]. Piracicaba: ESALQ; 1988.

Gonçalves JS, Perez LH. Relevância econômica da Banana em São Paulo e no Brasil. In: Nogueira EMC, Almeida IMG, Ferrari JT, Beriam LOS. eds. *Bananicultura: manejo fitossanitário e aspectos econômicos e sociais da cultura*. São Paulo: Instituto Biológico; 2013. p03-20.

Halkesford M, Horst W, Kichey T, Lambers H, Schjoerring J, Moller IS, White P. Functions of macronutrients. In: Marschner, P. ed. *Mineral nutrition of higher plants*. 3.ed. London: Academic Press; 2012.

Haykin S. *Neural Networks: a comprehensive foundation*. New York: MacMillan; 1999.

IBGE. Base de dados agregados [internet]. Brasília: instituto Brasileiro de Geografia e Estatística; 2016 [acesso em 06 fev de 2016]. Disponível em: <http://www.sidra.ibge.gov.br/bda/prevsaf/default.asp>.

Kovács ZL. *Redes neurais artificiais: fundamentos e aplicações*. 4. ed. São Paulo: Livraria da Física; 2002.

Lopez MA, Espinosa MJ. Manual de nutrición y fertilización del banano. Quito: INPOFOS; 1995.

Maathuis FJM, Physiological function of mineral macronutrients. Current Opinion of plant Biology. 2009; 12:250-258.

Malavolta E. Elementos de nutrição mineral de plantas. Piracicaba: Ceres, 1980.

Malavolta E. Manual de Nutrição Mineral de Plantas. Piracicaba: Editora Agrônoma Ceres; 2006.

Marques Filho O, Vieira Neto H. Processamento digital de imagens, Rio de Janeiro: Brasport; 1999.

Martin-Prével P. La nutrition minerale du bananier dans le monde. Fruits. 1980; 35:503-18.

McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bulletin of Math. Biophysics. 1943; 5:115-133.

Moraes WS, Zambolim L, Lima JD. Incidência de fungos em pós-colheita de banana (*Musa* spp.) 'Prata-anã' (AAB). Sum. Phytopatol. 2006; 32:67-70.

Raij B. Fertilidade do solo e manejo de nutrientes. Piracicaba: IPNI; 2011.

Schmidt CB. Bananeira Nanica. São Paulo: Secretaria de Agricultura do Estado de São Paulo; 1934.

Sena-Júnior DG, Pinto FAC, Gomide LA, Teixeira MM. Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por *Spodoptera frugiperda*. Rev. Bras. Eng. Agríc. Ambiental; 2003. 7:359-366.

Silva JTA, Borges AL, Malburg JL. Solos, adubação e nutrição da bananeira. Belo Horizonte. 1999; 20:21-36. (Informe agropecuário).

Silva SHMG. Processamento digital de imagens para identificação da Sigatoka Negra em bananais utilizando redes neurais artificiais [tese]. Botucatu: UNESP; 2008. 83p.

Teixeira EF, Cicero SM, Dourado Neto D. Análise de imagens digitais de plântulas para avaliação do vigor de sementes de milho. Londrina: Rev. Bras. Sementes. 2006; 28:56-61.

Venturini RP, Bastos ARR, Mendonça AVR, Carvalho JG. Effects of the Ca:Mg relation on the development and mineral nutrition of aroeira plants (*Myracrodruon urundeuva* Fr. All.). Cerne. 2000; 6:30-39.

Vieira LM. Banana: Produção e mercado mundial. Síntese Anual da Agricultura de Santa Catarina - 2012-2013 [internet]. Santa Catarina: EPAGRI; 2013 [acesso em 20 jul de 2015]. Disponível em: [http://docweb.epagri.sc.gov.br/website\\_cepa/publicacoes/sintese\\_2013.pdf](http://docweb.epagri.sc.gov.br/website_cepa/publicacoes/sintese_2013.pdf).

Vitti GC, Lima E, Cicarone F. Cálcio, Magnésio e Enxofre. In: Fernandes MS. ed. Nutrição Mineral de Plantas. Viçosa: SBCS; 2006. p.299-322.

Wu J, Wang D, Rosen CJ, Bauer ME. Comparison of petiole nitrate concentrations, SPAD chlorophyll readings, and Quick Bird satellite imagery in detecting nitrogen status of potato canopies. Field Crops Research. 2007; 101:96-103.

Yuyama, LKO, Macedo SHM, Yonekura L, Aguiar JPL, Yuyama K. Perfil nutricional das diversas formas de consumo de banana (*Musa paradisiaca*, variedade pacovã) da Amazônia brasileira. Acta amazôn. 2000; 30:677-680.

## **CAPÍTULO 1. PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE DEFICIÊNCIAS DE CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA EM CASA DE VEGETAÇÃO**

### **RESUMO**

A diagnose visual é uma ferramenta útil na identificação de distúrbios fisiológicos em plantas, onde deficiências nutricionais são geralmente os mais comuns. A identificação visual de deficiências nutricionais se dá pelo conhecimento do observador, entretanto muitas vezes necessita de comprovação mediante a análise do tecido vegetal. A deficiência conjunta de nutrientes dificulta ainda mais a correta identificação visual, e resulta muitas vezes do manejo inadequado da fertilidade do solo. Dentre as frutíferas, a banana tem grande importância mundial e sua produtividade demanda de altas e adequadas concentrações de nutrientes no solo. Cálcio e magnésio estão entre os elementos exigidos pela bananeira, e seus sintomas de deficiência podem ocorrer em conjunto, pois são aplicados no solo via calcário. O uso de redes neurais artificiais aplicadas à análise de imagens digitais para identificação de padrões e classificação vem se disseminando nas ciências agrárias. Deste modo, uma sequência de experimentos com cinco épocas de coleta e cinco variações nutricionais foi realizada em casa de vegetação a fim de verificar a capacidade das redes neurais em identificar corretamente deficiências de cálcio, magnésio e ambas, em imagens de folhas de banana. O classificador obteve variações na taxa de acerto de acordo com as épocas de coleta, deste modo determinaram-se os melhores períodos de identificação para as deficiências de cálcio, magnésio e ambos em 60, 90 e 60 dias, respectivamente. Após a seleção das classes nas melhores épocas de coleta para a geração de uma nova base de dados, o classificador gerado apresentou uma média de acerto 29 % maior que nos testes anteriores, com taxas de acerto de 90, 73, 97 % para identificação das classes omissão de cálcio, omissão de magnésio e omissão de cálcio e magnésio, respectivamente. Foram identificadas também diferenças nos padrões de cores das folhas para os sistemas de cultivo hidropônico em solução nutritiva completa e cultivo em solo.

Palavras-chave: Omissão de nutrientes. Solução nutritiva. Bananicultura. Redes Neurais Artificiais.

# **CHAPTER 1. DIGITAL IMAGES PROCESSING FOR IDENTIFICATION OF CALCIUM AND MAGNESIUM DEFICIENCIES IN BANANA CROPS IN GREENHOUSE**

## **ABSTRACT**

The visual diagnosis is a useful tool on the identification of physiological disturbs in plants, where nutritional deficiencies are more common. The identification of nutritional deficiencies is made by the knowledge of the observer, though, many times, is necessary a vegetal tissue analysis to prove that. The combined deficiencies of nutrients difficult the correct visual diagnosis and this, many times, is the result of an inadequate management of soil fertility. The banana, among all fruits, has a worldwide importance and this productivity needs high and appropriate nutrients concentrations on the soil. Calcium and magnesium are among elements required by banana plants, and their symptoms of deficiency can occur together, because they are apply in soil via limestone. Use of Artificial Neural Networks (ANNs) applies to the digital images to identification of standards and classifications have spread in agrarian sciences. That way, a sequence of experiments with five collect times and five nutritional variations was performed in a greenhouse to check the capacity of ANNs to identify nutritional deficiency of calcium, magnesium and both correctly, in images of banana leaflets. The classifier obtained variations in hit rates according to sampling times. Thus, were determined the best periods to identify deficiency of calcium, magnesium and both in 60, 90 and 60 days, respectively. A new database was made after selected the best sampling times classes, the generated classifier presented 29 % improvement than the previously tests, with a hit rate of 90, 73 and 97 % for the identification of calcium omission, magnesium omission and calcium + magnesium omission classes, respectively. Were also identified differences in the leaflets color standards for the hydroponic cultivation system in complete nutritional solution and soil cultivation system.

Key-words: Nutrient omission. Nutritional solution. Banana cultivation. Artificial Neural Networks.

## 1.1. INTRODUÇÃO

Na fruticultura mundial, a banana ocupa a segunda colocação em produção (FAO, 2014) e, juntamente com outros produtos, é considerada uma fonte alimentar de alta importância, bem como responsável pela fixação e manutenção do homem no campo (Perrier et al., 2011). O Brasil ocupa a quarta posição dentre os maiores produtores com quase a totalidade do produto voltado ao mercado interno (IBGE, 2013).

Dentre a diversidade de genótipos apresentados pela espécie as cultivares Grande Naine, Prata, Pacovan, Maçã e Terra são as mais utilizadas. São plantas que exigem uma boa drenagem e possuem alta demanda de nutrientes, com exportações médias de 8,2 e 1,9 kg de K e N e 0,3 kg de Ca, Mg e P por tonelada de produto colhido (Azeredo et al., 1986; Soares et al., 2008).

Turner e Barkus (1973) e Lahav (1986) enfatizaram que a falta ou desbalanço de nutrientes no solo pode comprometer a distribuição destes elementos na bananeira devido ao seu crescimento acelerado e acúmulo de nutrientes, e que a baixa produtividade está relacionada ao inadequado manejo da adubação no ciclo da cultura e à baixa fertilidade do solo (Borges et al., 1999).

Sabe-se que o K é o macronutriente mais exigido pela cultura e que, muitas vezes, os demais macronutrientes acabam por serem negligenciados ou mal manejados (Silva e Carvalho, 2005). O excesso de K e/ou a ausência dos demais cátions Ca e Mg em quantidades adequadas podem interferir no ideal desenvolvimento da planta. O desbalanço nutricional pode influenciar no crescimento e desenvolvimento da cultura afetando sua produtividade ao final do ciclo (Borges, 2004).

O Ca possui função estrutural ligando-se aos pectatos que formam a parede celular. Sua ausência compromete a boa formação dos órgãos da planta limitando a área foliar, tamanho da planta e crescimento de raízes e frutos. O Mg possui função de ativador enzimático e componente estrutural da clorofila, sua ausência interfere diretamente na produção dos fotoassimilados necessários para planta se desenvolver (Hawksford et al., 2012).

Para culturas perenes, a identificação precoce e correta dos sintomas de deficiência pode resultar na manutenção da produtividade ou redução das perdas no ciclo (Pestana et al., 2003). Deste modo, tem-se buscado cada vez mais técnicas que solucionem problemas de campo com agilidade e em tempo real.

O uso de modelos matemáticos e técnicas computacionais para a resolução de problemas do campo tem se tornado mais comuns com o avanço das bases científicas e mais

confiáveis do ponto de vista técnico. O processamento digital de imagens (PDI) é uma destas técnicas, sendo utilizado na determinação da cobertura de solo (Varella et al., 2002), identificação de pragas (Sena-Júnior et al., 2003) e doenças (Venturini et al., 2015), e, ainda na recomendação de adubação (Bagheri et al., 2013), entre outras.

Sena Junior et al. (2003) utilizou a técnica de redes neurais artificiais (RNA) na identificação do ataque da lagarta do cartucho (*Spodoptera frugiperda*) a partir de imagens obtidas do alto das plantas. Haykin (2009) defende que redes neurais artificiais são modelos de estrutura robusta com capacidade de autoaprendizagem e generalização o que as tornam capazes de resolver problemas complexos e que envolvam grande quantidade de dados.

A arquitetura de uma rede neural é baseada na simulação da estrutura dos neurônios biológicos, com processamento em paralelo (camadas), podendo modelar variáveis categorias e numéricas em relações não lineares. São capazes de reconhecer padrões e possuem tolerância à presença de dados discrepantes (*outliers*) (Haykin, 2001).

Devido à falta de trabalhos com o tema na identificação de sintomatologias de deficiência nutricionais em frutíferas este trabalho teve por objetivo avaliar o desempenho das RNA com uso do PDI na correta identificação das deficiências de cálcio, magnésio e sua associação (cálcio + magnésio) em mudas de bananeira cultivadas em casa de vegetação, em cultivo hidropônico.

## **1.2. MATERIAL E MÉTODOS**

### **1.2.1 CASA DE VEGETAÇÃO**

Esta etapa do experimento foi realizada de janeiro a julho de 2014, em casa de vegetação na Universidade Estadual Paulista “Júlio de Mesquita Filho” – Unesp, na Unidade Agrochá, do Câmpus Experimental de Registro - CERe, em Registro – SP, com coordenadas geográficas 24°32'08,57" sul, 47°51'54,53" oeste e altitude de 26 m. O clima da região é segundo Köppen classificado como temperado úmido – Cfa.

A casa de vegetação possuía uma área de 105m<sup>2</sup>, coberta com polietileno aditivado anti-UV de 200 µm de espessura, paredes laterais de alvenaria até a altura de 0,80 m do nível do solo e 1,5 m de tela anti-afídeos, com malha de 50 mesh entre a parede de alvenaria e a cobertura, em condições naturais de luz, temperatura e fotoperíodo.

Foram utilizadas mudas micropropagadas e certificadas da cultivar Grande Naine, as quais foram submetidas a um delineamento experimental em blocos casualizados, em esquema fatorial 5x5, com três repetições. Os fatores foram variações nutricionais [Solução



nutritiva completa, omissão de cálcio, omissão de magnésio, omissão de cálcio e magnésio; e cultivo em solo] e épocas de amostragem [0, 30, 60, 90 e 120 dias após a aplicação das variações nutricionais].

Após a obtenção das mudas, em estágio comercial ( $12 \pm 2$  cm), as raízes das plantas foram submetidas à lavagem, a fim de retirar todo o substrato (casca de pinus) aderido ao sistema radicular, para o transplântio no cultivo hidropônico, as quais ainda foram aclimatadas em suas respectivas soluções nutritivas previamente à aplicação dos tratamentos, em bandejas plásticas de 50 L com aeração constante, realizada com auxílio de uma Soprador (Turbina de ar Resun GF 180<sup>®</sup>), exceto para o cultivo em solo. Para tanto, as mudas destinadas ao cultivo em solução nutritiva permaneceram 10 dias em cada uma das respectivas soluções com 25, 50 e 75 % da força iônica sucessivamente. Após 30 dias, iniciaram-se os tratamentos (tempo zero) com 100% da força iônica. A solução nutritiva utilizada foi a de Hoagland e Arnon (1950) com alteração no aumento da concentração de Fe.

O solo empregado no nível de variação nutricional Solo possuía as características: pH ( $\text{CaCl}_2$ ) de 5,7; matéria orgânica=17 g  $\text{dm}^{-3}$ ; P(resina)=154 mg  $\text{dm}^{-3}$ ; S=9 mg  $\text{dm}^{-3}$ ; K=2,5; Ca=56; Mg=35; H+Al=19; soma de bases=93,5; CTC=112,5 e Al=0 todos em  $\text{mmol}_c \text{dm}^{-3}$ , e a saturação de bases em 83 %. Em relação aos micronutrientes, observou-se as concentrações de B=0,27, Cu=2,6, Fe= 81, Mn=140,4 e Zn=5,0 todos em  $\text{mg dm}^{-3}$ .

Não havendo a necessidade de correção da acidez do solo (Teixeira et al., 1997), a adubação básica seguiu a recomendação de Malavolta (1980), empregando as fontes de sulfato de amônio, superfosfato simples, cloreto de potássio, ácido bórico, sulfato de cobre, molibdato de sódio e sulfato de zinco. As adubações com N e K foram parceladas em 4 aplicações, aos 15, 30, 45 e 60 dias após o transplântio.

Após a lavagem do sistema radicular, as mudas destinadas aos tratamentos com solução nutritiva foram transplantadas individualmente para baldes plásticos de 15 L, permanecendo suspensas e sustentadas na região do coleto por placas de isopor de 4 cm de espessura e 30 cm de diâmetro. Em cada vaso foram colocadas 3 plantas, de modo que apenas 1 delas foi selecionada na amostragem.

A condução dos tratamentos e o preparo das soluções seguiram as recomendações de Furlani et al. (1999). O pH da solução nutritiva foi monitorado diariamente, com uso de um medidor portátil, ajustado a 5,5 ( $\pm 0,5$ ) com solução NaOH ou HCl a 0,1  $\text{M L}^{-1}$ .

A reposição da água evapotranspirada foi realizada diariamente, com água deionizada, antecedendo sempre o ajuste do pH para os cultivos em solução nutritiva. A solução nutritiva

foi renovada quinzenalmente, sendo empregado no preparo de todas as soluções-estoque reagentes puros para análise.

As amostragens realizadas nos períodos avaliados constituíram da coleta e segmentação da planta em folhas, pseudocaule e raízes, para posterior lavagem e secagem em estufa de ventilação forçada de ar a 65° C, até atingir massa constante. A terceira folha totalmente expandida de cada uma das plantas amostradas (folha índice), contadas a partir do ápice, segundo adaptação da indicação de Martin-Prével (1984) para coleta da folha diagnóstica, foram encaminhadas para análise computacional, anteriormente à lavagem, e, posteriormente, foram incorporadas novamente à matéria vegetal das folhas e seguiram para lavagem, secagem e posterior moagem em moinho tipo Willey para porvindoura análise de nutrientes, seguindo a metodologia de Bataglia et al. (1983). A eficiência de uso foi calculado como proposto por Siddiqi e Glass (1981) (matéria seca total<sup>2</sup>/ nutriente na matéria seca total).

Os resultados obtidos foram submetidos à análise de variância, com a aplicação do teste F e, quando o F foi significativo ( $p < 0,05$ ), as médias dos níveis do fator variações nutricionais foram comparadas pelo teste de Tukey ( $p < 0,05$ ) e foi realizado um estudo de regressão para os efeitos do fator época de amostragem.

### 1.2.2. COMPUTACIONAL

Realizou-se um experimento computacional para identificação dos sintomas de deficiências nutricionais a partir das folhas índices coletadas para cada um dos 25 tratamentos. Foi utilizado o processamento digital de imagens, composto por quatro fases distintas de operacionalização: (1) coleta e digitalização das amostras, (2) segmentação e extração dos histogramas das imagens, (3) seleção de atributos e, por último, (4) classificação. O experimento computacional total foi composto de seis experimentos rodados um para cada época (fator 2) e um com todas as épocas.

Na fase 1, foram coletadas as folhas índices das plantas e levadas ao laboratório da Unesp – CERE. As folhas foram separadas e classificadas de acordo com sua variação nutricional (Fator 1) em cada uma das épocas (Fator 2): solução completa (Comp), omissão de cálcio (-Ca), omissão de magnésio (-Mg), omissão de cálcio e magnésio (-Ca/Mg) e solo (Solo). Seguindo na Fase 1 e logo após a coleta e a classificação, foram obtidas imagens digitais de cada uma das folhas, em scanner de mesa HP®, com resolução de 600 dpi. Às imagens foram atribuídas classes correspondentes aos níveis do Fator 1.

Na fase 2, de cada imagem, foram extraídas 20 subamostras, com o software GIMP®, com dimensões de 100 x 100 pixels, totalizando 300 subamostras para cada época e 1500

subamostras totais [5 níveis (Fator1) x 5 níveis (Fator 2) x 3 repetições x 20 subamostras]. As amostragens digitais foram coletadas na região de maior expressão do sintoma de deficiência e, quando não observados ou não existentes, foram coletadas nas regiões de maior incidência dos sintomas conforme as plantas deficientes.

Ainda na Fase 2, para cada subamostra foram extraídos os três componentes do sistema de cores RGB (*red green e blue*) com 256 tons de cinza. De cada componente, foram extraídos histogramas da distribuição de pixels na escala de cinza variando de 0 (preto puro) a 255 (branco puro), com o uso do software SPRING (Camara et al., 1996). Os histogramas gerados foram armazenados digitalmente em arquivos textos no formato (.txt), onde, posteriormente, foram agrupados formando uma base de dados, também armazenado em arquivo texto. Essa base de dados consistiu de 1500 linhas, referentes ao número de subamostras, onde cada linha conteve 769 variáveis, sendo 768 variáveis de entrada compostas pela frequência de cada nível de cinza para cada componente do sistema RGB [256\*3] e uma variável de saída correspondente à classificação original da amostra de acordo com o nível do Fator1(classificação).

A partir da Fase 4 a base de dados foi submetida ao software WEKA (Cunningham e Denize, 1995), onde a análise multivariada aplicada para da seleção de atributos, com a técnica de Análise de Componentes Principais, visou diminuir expressivamente o número de variáveis de entrada substituindo-as por componentes principais selecionadas quanto ao grau de importância na classificação dos sintomas, sem prejuízo da informação biológica contida na variabilidade das respostas (Johnson e Wichem, 2002).

Por fim, na Fase 4, para a classificação das imagens utilizou-se a técnica de Redes Neurais Artificiais (RNA). O tipo de RNA foi a Perceptron multicamadas, treinadas com o algoritmo *backpropagation*. Foram utilizados os valores de 0,2 e 0,3 para as taxas de aprendizado e termo momentum (Haykin, 1999), respectivamente. Nesta etapa também foi utilizada a ferramenta Weka.

Para obter uma estimativa não viciada de erro do classificador, utilizou-se de técnicas de amostragem para manipulação dos conjuntos de treinamento e teste. Neste trabalho, foi considerada a metodologia r-partição *cross-validation* (Efron e Gong, 1983; Efron e Tibshirani, 1993), que divide o conjunto de dados total, de tamanho  $n$ , em  $r$  partes mutuamente exclusivas (partições) de tamanhos iguais a  $n/r$  amostras. As amostras nos  $(r - 1)$  partições são usadas para treinamento e a hipótese induzida é testada na partição remanescente. Este processo é repetido  $r$  vezes, cada vez considerando uma partição diferente

para teste. O erro no *cross-validation* é a média dos erros calculados em cada uma das  $r$  partições de teste (Baranauskas, 2000).

A rede neural possuiu três camadas e contou com 43 componente principais de entrada para T0, 33 para T30 e T60, 36 para T90, 40 para T120 e 53 para T\_Total. O número de nós que compuseram a arquitetura da rede neural foram 28, 23, 30, 24, 26, 33 e 25 para T0, T30, T60, T90, T120 e T\_Total, respectivamente.

Para verificar a consistência e confiabilidade dos resultados foi observada a taxa de erro do classificador, taxa de acerto do classificador, raiz quadrada do erro quadrático médio e as percentagens de acerto para cada classificação (Sena-Júnior et al., 2003).

Foi aplicado o teste diagnóstico (Galen e Galbino, 1975) nos resultados de classificação obtidos com a aplicação da técnica de RNA para os seis experimento (5 épocas de coleta + conjunto delas), a fim de verificar a sensibilidade e especificidade do modelo.

### 1.3. RESULTADOS E DISCUSSÃO

#### 1.3.1. CASA DE VEGETAÇÃO

Foram observados efeitos significativos dos valores de F no acúmulo de massa da matéria seca das folhas, pseudocaule, raízes e total, observando-se interação significativa entre as variações nutricionais e as épocas de coleta (TABELA 1).

TABELA 1. Valores de F para a massa da matéria seca de diferentes frações da planta em relação às variações nutricionais nas diferentes épocas de coleta.

Causas Variação	Massa da Matéria Seca <sup>1</sup>			
	Folhas	Pseudocaule	Raízes	Total
Variações nutricionais (Vn)	87,21**	64,92**	88,62**	39,10**
Época de coleta (Ec)	14,85**	13,15**	17,33**	7,92**
Vn x Ec	2,61**	3,62**	3,08**	8,98**
C.V. (%)	20,6	26,3	19,3	8,7

<sup>1</sup>  $y = \text{raiz}(x+0,5)$ ; \*\*: significativo a  $p < 0,01$ .

Dentro de cada época de coleta o acúmulo da massa da matéria seca nas frações folhas, pseudocaule e raízes, variou entre os níveis de variação nutricional, não se observando um padrão. Verifica-se, ao final do período de avaliação (120 dias), que o maior acúmulo total da massa na matéria seca, numericamente, foi obtido na solução completa, contudo esta diferiu somente da omissão de Mg, nível este que implicou nas maiores perdas de acúmulo massa da matéria seca em todos os órgãos avaliados (TABELA 2).

TABELA 2. Resultados médios da massa da matéria seca ( $\text{g planta}^{-1}$ ) de diferentes frações da planta em relação aos níveis dos fatores estudados.

Variação Nutricional	Folhas		Pseudocaule		Raízes		Total	
----- 0 dias -----								
Solo	2,41	ab	1,18	a	0,42	ab	4,02	ab
Comp.	5,83	a	0,75	ab	0,80	a	5,41	a
-Ca	0,54	b	0,80	b	0,31	ab	0,93	b
-Mg	0,33	b	0,80	b	0,10	b	0,51	b
-Ca/Mg	0,52	b	0,90	b	0,10	b	0,71	b
----- 30 dias -----								
Solo	9,40	ab	4,03	a	1,51	a	14,94	a
Comp.	11,40	a	2,12	a	2,18	a	15,35	a
-Ca	10,36	a	2,59	a	2,36	a	15,31	a
-Mg	3,22	b	1,05	a	1,09	a	5,36	a
-Ca/Mg	4,32	ab	0,84	a	1,00	a	6,17	a
----- 60 dias -----								
Solo	14,67	ab	4,84	a	2,78	a	22,29	a
Comp.	22,77	a	9,78	a	6,09	a	38,65	a
-Ca	18,50	ab	8,78	a	5,00	a	32,39	a
-Mg	2,25	b	1,01	a	1,14	a	4,41	a
-Ca/Mg	16,41	ab	5,27	a	3,68	a	25,36	a
----- 90 dias -----								
Solo	16,87	a	5,84	a	3,77	b	26,49	a
Comp.	47,05	a	17,95	a	12,57	a	77,57	a
-Ca	41,12	a	18,78	a	11,24	a	21,14	a
-Mg	25,05	a	9,34	a	7,95	ab	42,34	a
-Ca/Mg	47,67	a	16,02	a	10,70	a	74,39	a
----- 120 dias -----								
Solo	23,59	ab	8,96	bc	6,05	b	38,60	ab
Comp.	51,20	a	33,39	ab	17,77	a	102,36	a
-Ca	47,40	ab	34,86	a	13,47	ab	95,73	ab
-Mg	18,82	b	5,57	c	3,41	b	27,81	b
-Ca/Mg	26,94	ab	19,52	abc	9,70	ab	56,16	ab

Médias seguidas da mesma letra não diferem entre si pelo teste de Tukey, na coluna ( $p < 0,05$ ), para cada época avaliada.

Uma possível explicação à diminuição da massa da matéria seca pela omissão desse nutrientes pode ser atribuída a consequente redução da fotossíntese, devido a função que o magnésio exerce como componente da molécula da clorofila. Como relatado por Kirkby (2012), a exigência de carbono pelas plantas é maior que a de qualquer outro nutriente, portanto o comprometimento do aporte de C pela diminuição da fotossíntese, resultante da omissão de magnésio, pode ter determinado os menores rendimentos do acúmulo de massa para este tratamento.

A equivalência no acúmulo da massa da matéria seca dos diferentes órgãos nos períodos avaliados também pode ser atribuída às reservas de nutrientes presentes nas mudas, quando da implantação do experimento, as quais foram suficientes para manter os níveis de acúmulo da matéria seca observados.

Observando-se a eficiência na utilização de nutrientes, verificou-se que o nível de variação Solo foi o que mais se destacou, obtendo a maior eficiência na utilização de N, P e K, que os demais níveis de variação. Isto porque a disponibilidade desses elementos e os teores encontrados (TABELA 5) para este nível de variação foram sempre menores, forçando-o a ser mais eficiente na utilização destes elementos, ocorrendo o oposto com o nível de variação Comp. (TABELA 3).

TABELA 3. Valores médios da eficiência de uso de nutrientes pelos diferentes níveis de variação nutricional aos 120 dias após a aplicação dos tratamentos.

Variação Nutricional	Eficiência de utilização de nutrientes <sup>1</sup>				
	N	P	K	Ca	Mg
	------(matéria seca) g <sup>2</sup> g <sup>-1</sup> nutriente acumulado -----				
Solo	3,27 a	13,24 a	3,52 a	5,03 ab	8,66 a
Comp.	1,37 b	3,89 b	1,11 b	2,83 b	3,95 a
-Ca	2,10 b	5,97 b	1,60 b	7,42 a	4,92 a
-Mg	1,56 ab	4,10 b	1,15 b	2,86 b	8,96 a
-Ca/Mg	1,15 b	2,81 b	0,96 b	3,26 b	5,21 a
F	11,7**	23,6**	28,1**	5,8*	3,2 <sup>ns</sup>
C.V., %	22,62	24,91	18,45	33,11	34,64

<sup>1</sup> y=raiz(x+0,5); \*\* e \*: significativo a p <0,01 e p<0,05.

Já para o nível de variação -Ca, observou-se a maior eficiência na utilização de cálcio, seguido pelo nível Solo. À medida que um elemento se torna escasso para a planta, ela necessita cada vez mais tornar-se eficiente na utilização do mesmo, como um mecanismo compensação, de modo a evitar o aparecimento de distúrbios fisiológicos. Não houve diferença significativa na eficiência de utilização de magnésio para os níveis de variação (TABELA 3).

O nível de variação com solução completa não diferiu estatisticamente dos demais níveis, exceto para os casos acima descritos, porque nessa condição, a produção de biomassa pelas plantas não sofre incremento na mesma proporção que a absorção e o acúmulo do nutriente nos tecidos, havendo, nesse caso, declínio na utilização interna do nutriente para a produção de biomassa (Siddiqi e Glass, 1981).

A relação Ca:N pode ter influenciado nas maiores taxas de crescimento no nível de variação -Ca, no caso deste experimento a relação Ca:N no cultivo em solução nutritiva Completa (Comp.) foi de 1,4:1, já na omissão de cálcio (-Ca) obteve-se relação 0:9. Sabe-se que existe um efeito antagônico da presença de Ca limitando a absorção de N (Marengo e Lopes, 2009) deste modo, a ausência de Ca pode favorecer o aumento dos teores de N na planta estimulando assim um maior crescimento; o que não foi observado no presente estudo em nenhum dos períodos avaliados (TABELA 5). Entretanto, este fato não pode ser atribuído a todas as plantas, Monteiro et al. (1995) observou a ocorrência deste fenômeno em braquiária, já Vale et al. (2011) relatou a diminuição no crescimento da cana-de-açúcar com a omissão de Ca em solução nutritiva.

Foram observados efeitos significativos dos valores de F nos teores de nutrientes na planta e a interação das variações nutricionais com as épocas de coleta (TABELA 4).

TABELA 4. Valores de F para o teor de nutrientes da planta toda em relação às variações nutricionais nas épocas de coleta avaliadas.

Causas Variação	Nutrientes				
	N	P	K	Ca	Mg
Variação nutricional (Vn)	39,15**	101,65**	6,93**	24,85**	90,74**
Época de coleta (Ec)	7,92**	78,85**	54,53**	209,38**	760,36**
Vn x Ec	8,99**	6,27**	2,32**	2,53**	10,49**
C.V. (%)	8,7	10,6	15,1	14,9	8,5

<sup>1</sup>  $y = \text{raiz}(x+0,5)$ ; \*\*: significativo a  $p < 0,01$ .

Observou-se influência das variações nutricionais na planta toda, nos teores de N até os 60 dias de avaliação, a partir desse período os teores de N não foram alterados pelas diferentes variações nutricionais sofridas pelas plantas. Ao final do período de avaliação (120 dias) tem-se que, para os teores de nitrogênio (N), não houve diferença estatística entre as variações nutricionais. Para o fósforo (P), observou-se os maiores teores no nível -Mg, seguido por -Ca/Mg=-Ca>Comp.>Solo. Para o potássio (K), a ordem dos teores nos níveis de variação nutricional foi: -Mg>-Ca/Mg>-Ca>-Comp.>-Solo. Para o cálcio (Ca): Solo>-Mg>Comp.>-Ca/Mg>-Ca e, para magnésio, (Mg) tem-se: -Ca>Solo>Comp.>-Ca/Mg>-Mg (TABELA 5).

TABELA 5. Resultados médios dos teores de nutrientes ( $\text{g kg}^{-1}$ ) na planta em relação às variações nutricionais nas diferentes épocas de coleta.

Variação Nutricional	N	P	K	Ca	Mg
----------------------	---	---	---	----	----

----- 0 dias -----										
Solo	29,67		3,13	b	34,67	b	14,67	a	6,73	a
Comp.	45,33		5,30	a	88,33	a	8,67	b	4,20	b
-Ca			5,40	a	70,33	ab	6,67	b	5,26	b
-Mg			5,70	a	63,00	ab	9,50	b	2,56	c
-Ca/Mg			5,10	a	66,00	ab	7,67	b	1,97	c
----- 30 dias -----										
Solo	30,00	c	2,16	b	31,00	b	11,67	a	6,13	a
Comp.	35,33	bc	3,86	ab	80,00	a	7,67	b	4,00	b
-Ca	44,33	ac	5,43	a	77,33	a	2,67	c	5,93	a
-Mg	44,00	ac	4,97	a	73,33	a	8,33	ab	1,33	c
-Ca/Mg	48,33	a	5,20	a	75,33	a	5,00	bc	1,30	c
----- 60 dias -----										
Solo	33,36	ab	2,10	c	27,33	b	13,00	a	5,80	a
Comp.	29,67	b	3,20	bc	73,00	a	6,67	c	2,83	b
-Ca	28,00	b	3,07	bc	56,67	ab	2,00	d	3,33	b
-Mg	35,33	ab	5,40	a	65,33	a	8,67	b	1,86	c
-Ca/Mg	38,33	a	3,53	b	66,33	a	3,33	d	0,90	d
----- 90 dias -----										
Solo	34,33	a	1,73	b	28,33	b	12,67	a	5,43	a
Comp.	24,33	a	2,47	ab	60,67	a	5,33	bc	2,40	c
-Ca	28,00	a	2,77	a	51,00	ab	2,00	c	4,36	b
-Mg	30,00	a	2,67	ab	69,67	a	8,00	b	0,87	d
-Ca/Mg	29,00	a	2,87	a	58,67	ab	2,67	c	0,83	d
----- 120 dias -----										
Solo	31,67	a	1,83	c	27,00	c	13,33	a	4,30	a
Comp.	27,00	a	2,57	bc	52,00	b	4,67	bc	2,37	b
-Ca	28,33	a	3,10	ab	53,00	b	2,00	c	4,53	a
-Mg	33,33	a	3,90	a	78,67	a	8,33	b	0,80	c
-Ca/Mg	29,33	a	3,10	ab	62,00	ab	2,33	c	0,83	c

Médias seguidas da mesma letra não diferem entre si pelo teste de Tukey, na coluna ( $p < 0,05$ ), para cada época avaliada.

Os teores de P foram sempre menores no nível de variação Solo (TABELA 4). O P movimenta-se no solo por difusão, portanto, apesar de estar no nível de suficiência ( $P(\text{resina})=154 \text{ mg dm}^{-3}$ ) e contar com a adubação indicada por Malavolta (1980), a disponibilidade deste nutriente para as raízes em solo, é dependente da concentração deste elemento na região do sistema radicular. Diferentemente disto, a disponibilidade de P em solução nutritiva é muito maior que no solo, e conseqüentemente a obtenção deste elemento pela planta é facilitada. Apesar da disponibilidade deste nutriente no solo utilizado estar adequada, podem ocorrer interações deste elemento com os óxidos de Ca e Al, dificultando, de certa forma, sua mobilidade em direção às raízes (Novais et al., 2007).



Observou-se também que, os níveis de variação nutricional com omissão de nutrientes apresentaram os maiores teores de P a partir dos 90 dias, demonstrando uma interação inversa de P com Ca e Mg, onde a ausência destes elementos proporcionou maiores teores de P no tecido da planta. Nota-se nisto a ocorrência do efeito de concentração (Vale et al., 2011) para os níveis de variação nutricional -Mg e -Ca/Mg, de modo que a omissão destes nutrientes causou um menor crescimento, de folhas e pseudocaule (TABELA 2), principalmente, concentrando os elementos presentes em uma menor massa, resultando no aumento dos teores observados de P e K para estes níveis de variação nutricional.

O K foi o nutriente que mais se beneficiou da omissão de Ca e Mg, pois não encontrou competição pelos sítios de absorção nas raízes. Deste modo, a ausência de Ca e Mg diminuiu as interações e a competição entre os cátions na solução nutritiva, permitindo um aumento nos seus teores em relação ao nível de variação Solo, pois a ausência de cátions de maior valência favoreceu ainda mais o aumento nos teores deste elemento na planta (TABELA 5).

O nível de variação Solo foi o que apresentou os maiores teores de Ca e Mg. Um solo devidamente corrigido, com a presença de  $56 \text{ mmol}_e \text{ dm}^{-3}$  de Ca e saturação por bases de 83%, apresentam concentrações de Ca e Mg maiores que as necessárias para o adequado desenvolvimento da planta (Teixeira et al., 1997), fato que não ocorre em solução nutritiva, pois a correção do pH se dá por NaOH e HCl. Assim, a maior concentração de Ca e Mg no solo favorece também uma maior absorção destes elementos pela planta.

Já em solução nutritiva, a ausência de um destes cátions bivalentes promove um aumento no teor do outro, pois os sítios de absorção não específicos das raízes são preenchidos totalmente por um único elemento, por este motivo observamos que os níveis de variação nutricional -Ca e -Mg obtiveram teores maiores de magnésio e cálcio, respectivamente, que o nível de variação Solução Completa.

Os níveis de variação com ausência de cálcio e magnésio em solução nutritiva resultam em menores teores desses elementos na planta. Deste modo, pode-se garantir que as imagens obtidas nesse experimento condizem com as respectivas deficiências de cálcio e magnésio esperadas e observadas.

A análise de variância revelou o valor de F significativo para a variação nutricional, épocas de coleta e a interação Variação x Época no acúmulo dos nutrientes nas folhas, conforme a TABELA 6.

TABELA 6. Valores de F para o acúmulo de nutrientes nas folhas em relação à variação nutricional nas épocas de coleta avaliadas.

Causas Variação	Nutrientes				
	N	P	K	Ca	Mg
Variação nutricional (Vn)	79,55**	66,93**	70,60**	64,25**	73,98**
Época de coleta (Ec)	12,43**	18,56**	22,54**	34,85**	85,00**
Vn x Ec	2,34**	2,97**	2,99**	2,12**	5,25**
C.V. (%)	20,9	20,7	23,1	21,4	19,0

\*\* : significativo a  $p < 0,01$ .

Foram observados efeitos significativos entre os níveis de variação nutricional sobre o acúmulo de nutrientes para todas as épocas de coleta avaliadas, exceto para N a partir de 30 dias e para P aos 60 dias. Comparando-se os níveis de variação nutricional Solo (Solo) e Solução Completa (Comp.), pode-se observar uma dinâmica de acúmulo dos nutrientes diferenciada (FIGURAS 1a,b). Para o nível Comp., verificou-se que no final da avaliação (120 dias) a ordem de acúmulo foi  $K > N > Ca > P > Mg$ , diferindo do nível Solo, onde observou-se a ordem de acúmulo de  $N > K > Ca > Mg > P$  (TABELA 7).

A falta de fatores determinantes da série liotrópica no nível de variação nutricional Comp., ou seja, o solo e as interações que este exerce sobre os elementos que o cercam, reduziu a possibilidade de competição entre os cátions na solução, resultando num maior acúmulo de nutrientes pelas plantas quando comparado ao nível de variação Solo e na dinâmica diferenciada observada entre Solo e Solução Nutritiva Completa (FIGURAS 1A e B).

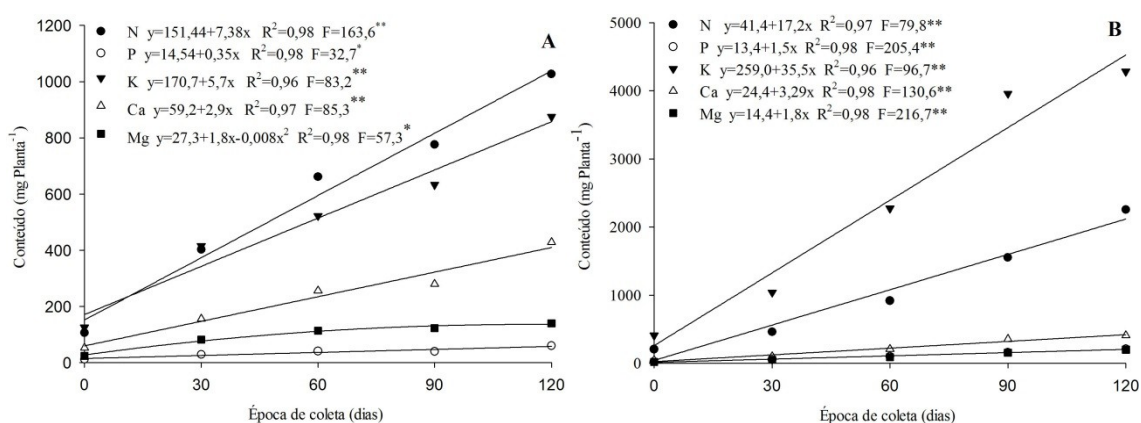


FIGURA 1. Equações, coeficiente de determinação ( $R^2$ ) e valor de F sobre os efeitos épocas de coleta (dias) no acúmulo de N, P, K, Ca e Mg nos níveis de variação Solo (A) e Solução Completa (B) em mudas de bananeira 'Grande Naine'. (\*, \*\*: significativo a  $p < 0,05$  e  $p < 0,01$ , respectivamente).

No cultivo em solução nutritiva não ocorrem relações de interação solo-solução, não havendo cargas dependentes de pH responsáveis pela maior retenção de alguns íons em

detrimento de outros (Meurer, 2006). Isto permite, por exemplo, que o K permaneça livre na solução e sua absorção seja facilitada, não havendo competição por sítios de absorção com cálcio (Ca) e magnésio (Mg), como ocorre no solo (Fonseca e Meurer, 1997; Paiva et al., 1998; Paiva e Oliveira, 2006).

A diferença na quantidade de nutrientes absorvida pelos tratamentos também pode ser explicada pela falta de interação dos mesmos com o solo no nível Comp., fazendo com que eles sejam absorvidos livremente pelas raízes, não necessitando dos mecanismos de contato específicos, fluindo todos por fluxo de massa (Almeida et al., 2013). Assim, a absorção de nutrientes no nível de variação Comp., para o elemento K, foi maior que no solo, provavelmente, por não haver tais interações e, para nitrogênio, por não haver processos de imobilização e mineralização, e menor no nível de variação Solo devido às interações dos nutrientes com os colóides do solo.

Deste modo, ensaios de marcha de absorção em sistemas de cultivo com solução nutritiva como meios de definição das necessidades de nutrientes, podem não ser os que melhor retratam a situação no campo, pois os mesmos não levam em consideração um fator crucial envolvido que é o solo. Isto se torna claro quando observamos que a diferença no acúmulo de nutrientes entre os níveis de variação é de aproximadamente 2,2 vezes para N, 3,5 vezes para P e 4,9 vezes para K. O que acarretará em indicações inadequadas ao período/demanda de um dado nutriente, devido aos diferentes ângulos das inclinações das equações de regressão (Figuras 1A e B), bem como em uma possível superestimação da quantidade adequada de fertilizantes a serem aplicados, se estudos desta magnitude forem utilizados para predizer cálculos de adubação.

TABELA 7. Resultados médios do acúmulo de nutrientes nas folhas ( $\text{mg planta}^{-1}$ ) em relação às variações nutricionais nas épocas de coleta avaliadas.

Variação Nutricional	N		P		K		Ca		Mg	
	----- 0 dias -----									
Solo	106,2		11,3	ab	125,0	ab	52,5	a	24,1	a
Completa	206,1		24,5	a	408,9	a	40,2	a	19,3	a
-Ca			3,4	b	44,9	b	4,0	b	3,2	b
-Mg			2,3	b	26,3	b	3,9	b	1,0	b
-Ca/Mg			3,2	b	45,7	b	4,6	b	1,1	b
	----- 30 dias -----									
Solo	402,3	a	29,0	ab	415,5	ab	155,7	a	82,1	a
Completa	462,3	a	50,9	ab	1039,5	a	101,1	ab	52,4	ab
-Ca	555,0	a	67,4	a	992,6	a	32,9	bc	76,2	a

-Mg	187,9	a	20,8	b	278,6	b	32,6	bc	6,3	b
-Ca/Mg	246,6	a	26,2	ab	386,3	ab	25,8	c	6,5	b
----- 60 dias -----										
Solo	661,19	a	40,6	a	522,1	b	255,3	a	113,6	a
Completa	918,27	a	101,5	a	2273,0	a	207,0	ab	89,1	ab
-Ca	747,47	a	84,9	a	1547,2	ab	53,7	ab	89,9	ab
-Mg	120,63	a	16,9	a	170,9	b	26,9	b	6,3	b
-Ca/Mg	670,14	a	63,9	a	1138,7	ab	75,2	ab	18,5	ab
----- 90 dias -----										
Solo	776,5	a	39,4	b	632,7	b	279,7	b	121,9	ab
Completa	1553,2	a	158,3	a	3959,5	a	354,6	a	155,9	ab
-Ca	1665,4	a	161,5	a	3079,7	ab	119,8	ab	253,8	a
-Mg	986,7	a	87,9	ab	2223,4	ab	268,2	ab	30,2	b
-Ca/Mg	1876,2	a	183,4	a	3760,2	a	173,3	a	53,6	b
----- 120 dias -----										
Solo	1027,4	a	59,9	b	874,8	b	428,0	a	139,6	ab
Completa	2254,0	a	209,9	ab	4283,7	a	407,9	a	199,9	ab
-Ca	2302,2	a	255,0	a	4429,8	a	164,5	ab	375,8	a
-Mg	818,9	a	95,1	ab	1920,1	ab	202,0	ab	19,5	b
-Ca/Mg	1385,7	a	146,4	ab	2993,7	ab	108,6	b	38,7	b

Médias seguidas da mesma letra não diferem entre si pelo teste de Tukey, na coluna ( $p < 0,05$ ).

Quando se observa o comportamento dos nutrientes cálcio e magnésio, em relação a suas omissões individuais ou associadas, verifica-se que não há diferença estatística no acúmulo destes nutrientes nos dois níveis de variação nutricional observados na maioria das épocas de coleta avaliadas (TABELA 7). O que reforça a indicação de Montagut e Martin-Prével, (1965) e Gomes (1988), que observaram em ‘Prata’ uma baixa absorção de nutrientes até o quarto mês, de modo que 75 % do N, P e K do ciclo da cultura foram absorvidos a partir de 180 dias e 210 dias para Ca e Mg.

Já Mengel e Kirkby (2001) e Malavolta (2006) relataram efeitos da diminuição da absorção de Ca e Mg em solução nutritiva com o aumento da concentração K. Contudo, apesar do conteúdo de K no nível de variação solução nutritiva ter sido maior que no solo, acredita-se que no presente estudo não ocorreu tal situação devido a constante e adequada concentração de K evidenciada pela equivalência no acúmulo de Ca e Mg entre os níveis de variação Comp. e Solo, durante todas as épocas de coleta avaliadas.

Como observado na TABELA 7, não houve diferença estatística no acúmulo de Ca e Mg entre os níveis de variação Solo e Comp., exceto para Ca aos 90 dias. Deste modo, foi realizada a correlação dos conteúdos de cálcio e magnésio entre os níveis de variação Comp. e Solo, a fim de verificar se a expressão dos sintomas de deficiência de Ca e Mg com o uso de

solução nutritiva ou solo com omissão destes nutrientes apresentará o mesmo comportamento (FIGURA 2A,B).




FIGURA 2. Equação, correlação linear de Pearson (r) e F sobre a relação do conteúdo de Ca (A) e Mg (B) entre os níveis de variação nutricional Solo e Comp. (\*: significativo a  $p < 0,05$ ).

As correlações lineares de Pearson apresentaram r de 0,95 e 0,90 para Ca e Mg, respectivamente, e ambos significativos a  $p < 0,05$  (FIGURA 2). Deste modo, verifica-se que existe uma alta e significativa correlação no acúmulo destes nutrientes entre os níveis de variação nutricional. Portanto, acredita-se que o comportamento esperado para a sintomatologia destes nutrientes independará do método de cultivo, se em solução ou no solo.

### 1.3.2. COMPUTACIONAL

#### 1.3.2.1. CLASSIFICAÇÃO DA REDE NEURAL ARTIFICIAL

Depois de selecionadas as componentes principais, a partir da matriz de correlação de dados, utilizaram-se essas componentes como vetores de entrada para a fase de classificação (TABELA 8). Assim, os vetores foram compostos pelas variáveis de entrada (componentes principais) e uma variável de saída, representando os cinco níveis de variação nutricional (classes) de cada uma das amostras, sendo eles: solução completa (Comp.), omissão de cálcio (-Ca), omissão de magnésio (-Mg), omissão de cálcio e magnésio (-Ca/Mg) e cultivo em solo (Solo). Realizou-se o treinamento da RNA para cada um dos cinco níveis do fator épocas de coleta (0, 30, 60, 90 e 120 dias) e um para o conjunto das épocas (T\_Total).

Tabela 8. Características da rede neural para as diferentes épocas de coleta e o conjunto delas.

Época de coleta	Nº de Componentes Principais	Nº de Nós da Rede Neural	Nº Camadas da Rede Neural
-----------------	------------------------------	--------------------------	---------------------------

T0	43	28	3
T30	33	23	3
T60	33	30	3
T90	36	24	3
T120	40	26	3
T Total	53	33	3

A FIGURA 3 representa a arquitetura da rede neural com as componentes principais como os valores de entrada, as camadas intermediárias responsáveis por todo o processo matemático de classificação e a saída/resposta dada pelo classificador gerado pela rede para cada uma das cinco classificações possíveis previamente estabelecidas.




FIGURA 3. Arquitetura da rede neural (T90) com valores de entrada (componentes principais), neurônios (processadores) e saída (classificação).

O experimento rodado na época de coleta T30 foi o que apresentou a maior taxa de acerto médio (64,33%) entre os conjuntos de teste, seguido das épocas T0, T60, T120, T\_total e T90. Por consequência, as épocas que apresentaram a maior precisão média, medida pela raiz quadrada do erro quadrático médio, seguiram tendência semelhante (TABELA 9).

TABELA 9. Desempenho médio na classificação dos conjuntos de teste para as épocas de avaliação e o conjunto total.

Desempenho	Época de coleta (dias)					
	T0	T30	T60	T90	T120	T_total

Erro	36,0 %	35,7 %	40,0 %	47,3 %	37,7 %	47,6 %
Acerto	64,0 %	64,3 %	60,0 %	52,7 %	62,3 %	52,4 %
RMSE	0,3329	0,3464	0,3583	0,4067	0,3527	0,3782

Nas TABELAS 10, 11, 12, 13 e 14 são apresentadas, respectivamente, as matrizes de confusão dos resultados médios das classificações para os conjuntos de teste, em cada uma das épocas avaliadas e para o conjunto total. As linhas representam os resultados dos conjuntos de teste para cada uma das classes estudadas, onde n representa o número de amostras classificadas em cada classe e % o equivalente em percentual desses valores. A matriz de confusão decompõem as taxas de erro e acerto médios nas classes, quantificando quantos exemplos da base foram corretamente classificados pelo modelo (diagonal principal) e quantos foram erroneamente classificados (valores dispersos da diagonal principal) (Cosme, 2002).

TABELA 10. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a época de coleta T0.

Origem		Destino					Total
		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
-Ca	n	32	10	17	1	0	60
	%	53,3 %	16,7 %	28,3 %	1,7 %	0,0 %	100 %
-Mg	n	11	23	26	0	0	60
	%	18,3 %	38,3 %	43,3 %	0,0 %	0,0 %	100 %
-Ca/Mg	n	8	32	20	0	0	60
	%	13,3 %	53,3 %	33,3 %	0,0 %	0,0 %	100 %
Comp.	n	1	0	0	58	1	60
	%	1,7 %	0,0 %	0,0 %	96,7 %	1,7 %	100 %
Solo	n	0	0	0	1	59	60
	%	0,0 %	0,0 %	0,0 %	1,7 %	98,3 %	100 %

Para a época de coleta T0 (TABELA 10), pode-se observar que os níveis de variação nutricional Solo e Comp. obtiveram as maiores taxas médias no conjunto de teste, 98,3 e 96,7 %, respectivamente, e que o erro destas classes ficou praticamente distribuído entre as mesmas, demonstrando a capacidade do classificador em identificar, já no início do estudo, uma diferença significativa entre as condições de cultivo. Isto porque, o período de aclimação das mudas à solução nutritiva gerou uma diferença com relação às mudas sobre cultivo em solo, que foram submetidas à situação de alta quantidade de nutrientes desde o início, tornando este efeito perceptível à análise do classificador. Já para as épocas de coleta seguintes, este efeito sofreu uma leve diluição, como observado nas demais matrizes.

Nos níveis de variação nutricional com omissão de nutrientes houve uma maior confusão entre as classes resultando em uma taxa de acerto menor que 55 % para todas elas, de modo que a classe -Ca foi a classe que obteve melhor desempenho (53,3%), seguido por -Mg e -Ca/Mg (38,3 e 33,3 %, respectivamente).

Com isso pode-se inferir que o T0, ou seja, 30 dias de aclimação das plantas em soluções com omissão de nutrientes, não foi suficiente para uma clara diferenciação dos padrões de deficiência destes nutrientes pelo programa. Em suma, para época de coleta, a capacidade do classificador não foi satisfatória na distinção entre deficiências, mas sim na indicação de que elas existiriam.

Na matriz de T30 (TABELA 11), tem-se uma diminuição do acerto das classes Comp. e Solo, com uma ligeira diluição das amostras erroneamente alocadas nas classes deficientes. Esta diluição foi maior para o nível de variação Comp., com 16,7 % das amostras confundidas com as classes deficientes, principalmente -Mg (8,3 %). Entretanto, este comportamento não revela uma tendência nas épocas futuras avaliadas.

TABELA 11. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a época de coleta T30.

Origem		Destino					Total
		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
-Ca	n	42	10	3	5	0	60
	%	70,0 %	16,7 %	5,0 %	8,3 %	0,0 %	100 %
-Mg	n	16	33	4	5	2	60
	%	26,7 %	55,0 %	6,7 %	8,3 %	3,3 %	100 %
-Ca/Mg	n	7	7	43	1	2	60
	%	11,7 %	11,7 %	71,7 %	1,7 %	3,3 %	100 %
Comp.	n	2	5	3	36	14	60
	%	3,3 %	8,3 %	5,0 %	60,0 %	23,3 %	100 %
Solo	n	1	3	0	17	39	60
	%	1,7 %	5,0 %	0,0 %	28,3 %	65,0 %	100 %

Salvo informação anterior, os erros das classes Comp. e Solo permaneceram restritos entre as mesmas, com taxa de acerto de 60 a 65 %, respectivamente. Este erro diluído dentro das classes Comp. e Solo (23,3 e 28,3 %) indicam que após 30 dias do início dos tratamentos as classes já tendem a se equiparar, ou seja, o efeito da aclimação do nível de variação nutricional Comp. não é mais tão expressivo.

Para as classes com omissão de nutrientes, o T30 foi o que obteve a melhor classificação nos níveis de variação -Ca e -Ca/Mg, com 70 e 71,7 % de acerto,



respectivamente, apresentando erro diluído de 20 a 23 % entre as demais classes de omissão. Com isso, pode-se determinar que a deficiência de cálcio possa ser identificada com clareza a partir de 60 dias [30 aclimação + 30 experimento] de sua indução, e que a deficiência de cálcio + magnésio, que é mais comum de encontrar-se no campo, possui precedência característica da deficiência de cálcio, e com o decorrer do tempo, de magnésio (TABELA 11).

Na matriz de confusão do nível T60, a classe -Mg apresentou a melhor classificação (83,3 %), estabelecendo-se 90 dias [30 aclimação + 60 experimento] como suficientes para o modelo obter uma alta taxa de acerto para a deficiência deste nutriente. Para o nível de variação nutricional Comp. e demais níveis com omissão, observou-se taxa de acerto abaixo de 50 %, com grande diluição das amostras entre as classes, exceto para a classe Solo, que obteve 70 % de acerto e 16,7 % do erro vinculado à classe Comp. (TABELA 12).

TABELA 12. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a época de coleta T60.

Origem		Destino					Total
		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
-Ca	n	29	2	14	9	6	60
	%	48,3 %	3,3 %	23,3 %	15,0 %	10,0 %	100 %
-Mg	n	4	50	3	2	1	60
	%	6,7 %	83,3 %	5,0 %	3,3 %	1,7 %	100 %
-Ca/Mg	n	11	5	30	11	3	60
	%	18,3 %	8,3 %	50,0 %	18,3 %	5,0 %	100 %
Comp.	n	12	2	8	29	9	60
	%	20,0 %	3,3 %	13,3 %	48,3 %	15,0 %	100 %
Solo	n	4	0	4	10	42	60
	%	6,7 %	0,0 %	6,7 %	16,7 %	70,0 %	100 %

O efeito de diluição das amostras fora de suas classes respectivas torna-se uma tendência nas demais épocas de coleta avaliadas (TABELAS 13 e 14), com taxas de erro de classificação, nos conjuntos de teste, acima de 40 %, exceto para as classes Comp. e Solo. Este efeito se deve à permanência das plantas sobre omissão de nutrientes gerando um agravamento dos sintomas de deficiência de cálcio, que passam a apresentar características semelhantes à deficiência de magnésio, como manchas e estriamentos longitudinais cloróticos evoluindo para lesões necróticas. Tais estriamentos são semelhantes em composição de cores, variando em tons de verde e amarelo, que se equiparam ao observado na deficiência de

magnésio, onde os bordos das folhas apresentam clorose em direção ao centro, mantendo parte das nervuras ainda verdes (Haag e Minami, 1988; Mengel e Kirkby, 2001; Prado, 2009).

Aos 90 dias (TABELA 13), a matriz de confusão dos conjuntos de testes apresentou alta taxa de acerto apenas para a classe Solo (71,7 %). As demais classes obtiveram taxas de 45 % ou menores, incluindo a classe Comp, cujos 35 % do erro obtido foram diluídos nas classes de omissão de nutrientes. A época T90 foi o que apresentou o pior desempenho médio (47 % da taxa média de acerto) dentre todas as épocas avaliadas e o conjunto total. Neste ponto do experimento, as características colorimétricas obtidas pelo processamento de imagens não foram suficientes para distinção segura entre as classes, sendo necessário valer-se de outras técnicas que permitam uma análise mais aprofundada das características morfológicas e texturais do tecido deficiente. Contudo, nas épocas de coleta anteriores, já foram obtidas altas taxas de acerto para todas as classes avaliadas no experimento.

TABELA 13. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a época de coleta T90.

Origem		Destino					Total
		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
-Ca	n	21	9	11	10	9	60
	%	35,0 %	15,0 %	18,3 %	16,7 %	15,0 %	100 %
-Mg	n	12	27	14	5	2	60
	%	20,0 %	45,0 %	23,3 %	8,3 %	3,3 %	100 %
-Ca/Mg	n	15	15	27	2	1	60
	%	25,0 %	25,0 %	45,0 %	3,3 %	1,7 %	100 %
Comp.	n	13	5	3	24	15	60
	%	21,7 %	8,3 %	5,0 %	40,0 %	25,0 %	100 %
Solo	n	5	1	0	11	43	60
	%	8,3 %	1,7 %	0,0 %	18,3 %	71,7 %	100 %

Para a época de coleta T120 (TABELA 14), a matriz de confusão da rede neural apresentou alta taxa de acerto para as classes Solo e Comp. (85 e 80 %, respectivamente), seguidas pelas classes -Ca/Mg, -Ca e -MG com taxa de acerto média de 48,9 %. Assim como na época T90, as classes com omissão de nutrientes mantiveram a tendência de diluição das amostras e altas taxas de erro.

TABELA 14. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a época de coleta T120.

Origem	Destino	Total
--------	---------	-------

		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
-Ca	n	30	12	13	4	1	60
	%	50,0 %	20,0 %	21,7 %	6,7 %	1,7 %	100 %
-Mg	n	21	24	14	1	0	60
	%	35,0 %	40,0 %	23,3 %	1,7 %	0,0 %	100 %
-Ca/Mg	n	13	13	34	0	0	60
	%	21,7 %	21,7 %	56,7 %	0,0 %	0,0 %	100 %
Comp.	n	1	0	1	48	10	60
	%	1,7 %	0,0 %	1,7 %	80,0 %	16,7 %	100 %
Solo	n	0	0	0	9	51	60
	%	0,0 %	0,0 %	0,0 %	15,0 %	85,0 %	100 %

Com o intuito de verificar a capacidade da rede neural em identificar as deficiências dos nutrientes independentemente da época de amostragem, foram retiradas da base de dados estas informações, mantendo-se somente as informações de classe, e posteriormente oferecidas à rede neural para classificação.

Os resultados obtidos nesta matriz de confusão ficaram de 10 a 15 % abaixo da média dos resultados obtidos nas épocas de coleta de 0 a 120 dias (TABELA 15). Deste modo, a classificador gerado pela rede neural não se mostrou eficiente na classificação das amostras na independência da época de amostragem. Este comportamento pode ter ocorrido devido a falta de padronização das amostras nas classes para construção do modelo, já que as características de deficiência não foram estáticas durante o tempo. Assim, com base apenas nas informações de cor, a rede pode não ter sido capaz de gerar padrões para a classificação.

Sena-Júnior et al. (2003), utilizando redes neurais para identificação da lagarta do cartucho (*Spodoptera frugiperda*), obteve 80,74 % de taxa de acerto média para as classificações de Solo, Folha Atacada e Folha Sadia. Venkatesh e Raja (2003), na classificação de imagens de satélite para identificação de cobertura do solo por diferentes culturas, obtiveram exatidão de 99% nas classes estudadas. Braz et al. (2014) aplicando redes neurais à predição de classes de solo obteve 95,6 % de acerto com base nas características geológicas. Tourian e Padilha (2008) obtiveram 57,5 % na taxa média de acerto da rede na classificação de variedades de soja pela morfologia da semente.

TABELA 15. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para o conjunto de amostras, excluindo-se a informação das épocas de coleta (T\_total).

Origem		Destino					Total
		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
-Ca	n	114	59	71	39	17	300

	%	38,0 %	19,7 %	23,7 %	13,0 %	5,7 %	100 %
-Mg	n	44	145	72	21	18	300
	%	14,7 %	48,3 %	24,0 %	7,0 %	6,0 %	100 %
-Ca/Mg	n	61	74	133	20	12	300
	%	20,3 %	24,7 %	44,3 %	6,7 %	4,0 %	100 %
Comp.	n	31	14	14	171	70	300
	%	10,3 %	4,7 %	4,7 %	57,0 %	23,3 %	100 %
Solo	n	8	5	4	60	223	300
	%	2,7 %	1,7 %	1,3 %	20,0 %	74,3 %	100 %

A FIGURA 4 apresenta a taxa de flutuação na taxa de acerto do classificador para cada uma das classes durante as épocas de coleta. Pode-se observar as melhores taxas de acerto, obtidas pelo classificador, para cada classe variaram com a época de coleta. Assim, pode-se inferir que para cada classe, existe um determinado momento onde suas características tornam-se distinguíveis das demais. Deste modo tem-se que a época de coleta que mais representou as classes Solo e Comp. foi a T0, -Ca e -Ca/Mg a T30 e para a classe -Mg a T60, representando respectivamente 30, 60 e 90 dias de indução dos níveis de variação nutricional.




FIGURA 4. Flutuação das taxas de acerto médias da rede neural para cada classe em cada época avaliada.

Após determinada a melhor época de classificação para cada classe e a fim de constatar a eficácia na classificação para aplicação do modelo em experimentos futuros, foram selecionadas as amostras dos níveis variação nutricional -Ca em T30, - Mg em T60, -Ca/Mg em T30, Comp. em T0 e Solo em T0 (FIGURA 4). Estas amostras compuseram uma nova

base, cuja eficácia foi avaliada por meio da matriz de confusão, gerada pelo classificador na classificação desta nova base (TABELA 16).

A matriz de confusão gerada pelo classificador a partir desta nova base de dados apresentou uma taxa média de acerto de 89 % (TABELA 16), o que significou uma melhora de 29 % em relação à média dos acertos das matrizes nas épocas de coleta de T0 a T120 dias (TABELA 9). Essa melhora na classificação refletiu-se principalmente nas classes -Ca e -Mg, que obtiveram uma melhora na classificação de 20 e 13,7 %, respectivamente, em comparação com as melhores taxas obtidas previamente para estas classes (TABELAS 10, 11, 12, 13, 14 e 15).

TABELA 16. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a base de dados da melhor época de classificação para cada classe.

Origem		Destino					Total
		Ca	Mg	Ca/Mg	Comp.	Solo	
Ca (T30)	n	54	0	5	1	0	60
	%	90 %	0 %	8 %	2 %	0 %	100 %
Mg (T60)	n	0	58	0	1	1	60
	%	0 %	97 %	0 %	2 %	2 %	100 %
Ca/Mg (T30)	n	10	0	44	5	1	60
	%	17 %	0 %	73 %	8 %	2 %	100 %
Comp. (T0)	n	2	1	3	53	1	60
	%	3 %	2 %	5 %	88 %	2 %	100 %
Solo (T0)	n	0	1	1	0	58	60
	%	0 %	2 %	2 %	0 %	97 %	100 %

Considerando que sensibilidade é a capacidade que o modelo apresenta de detectar os indivíduos verdadeiramente positivos, ou seja, de diagnosticar corretamente o grupo de amostras com deficiência; e que especificidade é a capacidade que o modelo diagnóstico tem de detectar os verdadeiros negativos, isto é, de diagnosticar corretamente os indivíduos sem deficiência (Fleiss, 1981), foi aplicado o teste de diagnóstico para verificar a sensibilidade e a especificidade dos modelos propostos.

Os níveis de variação nutricional foram separadas em dois grupos, com deficiência (-Ca, -Mg e -Ca/Mg) e sem deficiência (Comp. e Solo). Na TABELA 17 são apresentados os resultados do teste diagnóstico do modelo para cada época avaliada, para o conjunto das mesmas e para a nova base de dados formada a partir das melhores épocas de coleta para cada classe. As letras *a*, *b*, *c*, *d* e *n* na tabela representam: *a*- verdadeiro positivo, *b*- falso negativo, *c*- falso positivo, *d*- verdadeiro negativo e *n*- número de amostras. O positivo representa as

classes com omissão de nutrientes, enquanto que o negativo representa as classes sem omissão de nutrientes. O valor de sensibilidade é encontrado a partir de  $(a/(a+c))$  e a especificidade é encontrada a partir de  $(d/(b+d))$ , representando assim, a taxa de imagens do grupo com e sem deficiência corretamente classificadas.

TABELA 17. Teste diagnóstico dos resultados do classificador para os conjuntos de testes em cada época de avaliação e o conjunto das épocas.

Resultado do teste	População					Total
	Com deficiência		Sem deficiência			
----- 0 dias -----						
Positivo	$a$	179	$b$	1	$a + b$	180
Negativo	$c$	1	$d$	119	$c + d$	120
Total	$a + c$	180	$b + d$	120	$n$	300
----- 30 dias -----						
Positivo	$a$	165	$b$	14	$a + b$	179
Negativo	$c$	15	$d$	106	$c + d$	121
Total	$a + c$	180	$b + d$	120	$n$	300
----- 60 dias -----						
Positivo	$a$	148	$b$	30	$a + b$	178
Negativo	$c$	32	$d$	90	$c + d$	122
Total	$a + c$	180	$b + d$	120	$n$	300
----- 90 dias -----						
Positivo	$a$	151	$b$	27	$a + b$	178
Negativo	$c$	29	$d$	93	$c + d$	122
Total	$a + c$	180	$b + d$	120	$n$	300
----- 120 dias -----						
Positivo	$a$	174	$b$	2	$a + b$	176
Negativo	$c$	6	$d$	118	$c + d$	124
Total	$a + c$	180	$b + d$	120	$n$	300
----- T_total -----						
Positivo	$a$	773	$b$	76	$a + b$	849
Negativo	$c$	127	$d$	524	$c + d$	651
Total	$a + c$	900	$b + d$	600	$n$	1500
----- Nova Base de Dados -----						
Positivo	$a$	171	$b$	8	$a + b$	179
Negativo	$c$	9	$d$	112	$c + d$	121
Total	$a + c$	180	$b + d$	120	$n$	300

Na TABELA 18 são apresentados os valores de sensibilidade e especificidade do classificador gerado pela rede neural para todas as épocas de coleta, o conjunto total e para a

nova base de dados formada. Os resultados encontrados demonstram a variação da sensibilidade e especificidade em função das épocas de coleta. A sensibilidade do classificador foi sempre alta independente da época enquanto que para especificidade T\_total obteve valor de 0,43 apenas.

TABELA 18. Sensibilidade e especificidade do classificador para as épocas de coleta, o conjunto total e para a nova base de dados.

Causas	T0	T30	T60	T90	T120	T total	Nova Base
Sensibilidade	0,99	0,92	0,82	0,84	0,97	0,86	0,95
Especificidade	0,99	0,88	0,75	0,78	0,98	0,43	0,93

Observa-se que a capacidade do classificador em identificar a presença de alguma deficiência nutricional no grupo de amostragem (sensibilidade) foi maior em T0 (0,99), correspondente a 30 dias de adaptação das mudas às soluções nutritivas, seguida por T120, T30, T90, T\_total e T60. Já a especificidade foi maior em T0, seguida por T120, T30, T90, T60 e T\_total. Desse modo, observa-se que o classificador foi mais sensível que específico, resultando em uma melhor classificação do grupo com deficiência que do grupo sem deficiência.

Para a nova base de dados observa-se que valores de especificidade e sensibilidade encontrados no teste foram ambos altos, e maiores que a maioria dos valores encontrados para cada época de coleta avaliada, sendo os terceiros maiores valores. Do mesmo modo que nos resultados anteriores, a sensibilidade para a nova base de dados manteve-se maior que a especificidade, demonstrando que o classificador da nova base de dados manteve-se apto a identificar melhor o grupo com deficiência nutricional.

#### 1.4. CONCLUSÕES

1- Não houve diferença na marcha de absorção do cultivo em solo e solução nutritiva para os nutrientes cálcio e magnésio para a bananeira aos 120 dias, e ambos apresentaram alta correlação entre os métodos de cultivo.

2- O tempo necessário para melhor identificação dos sintomas de deficiência dos nutrientes foi de 60 dias para cálcio e cálcio + magnésio e 90 dias para magnésio.

3- O classificador foi capaz de identificar os níveis de variação nutricional com precisão de 90 % para omissão de cálcio, 73,3 % para omissão de magnésio, 96,7% para omissão de cálcio e magnésio, 88,3 % para solução nutritiva completa e 96,7% para cultivo

em solo, após seleção dos atributos nas melhores épocas de coleta, com melhora de 29% na média.

4- O classificador apresentou-se mais sensível que específico para a maioria das épocas avaliadas e para a nova base de dados.

## 1.5. LITERATURA CITADA

Almeida TBF, Prado RM, Flores RA, Politi LC, Barbosa JC. Avaliação nutricional do almeirão em soluções nutritivas suprimidas de macronutrientes. Scien. agrár. Paranaensis. 2013; 12:211-220.

Azeredo JA, Genú PYC, Aquino ARL, Campelo-Júnior JH, Rodriguez APM. Nutrição mineral e adubação da bananeira. In: Haag, HP Coord. Nutrição mineral e adubação de frutíferas tropicais do Brasil. 1ª ed. Campinas: Fundação Cargill; 1986. p.59-102.

Bagheri N, Ahmadi H, Alavipanah SK, Omid M. Multispectral remote sensing for site-specific nitrogen fertilizer management. Pesq. Agropec. Bras. Brasília. 2013; 48:1394-1401. doi: 10.1590/S0100-204X2013001000011

Baranauskas JA. Extração automática de conhecimento por múltiplos indutores [tese]. São Paulo: Instituto de Ciências Matemáticas e de Computação (USP); 2000.

Bataglia OC, Furlani AMC, Teixeira JPF, Furlani PR, Gallo JR. Métodos de análise química de plantas. Campinas: Instituto Agrônomo; 1983. (Boletim Técnico, 78)

Borges AL, Oliveira AMG, Souza, LS. Solos, nutrição e adubação. In: Alves EJ. editor. A cultura da banana: aspectos técnicos, socioeconômicos e agroindustriais. Brasília: Embrapa; 1999. p.197-260.

Borges AL. Interação entre nutrientes em bananeira. Cruz das Almas: Embrapa CNPMF; 2004. (Banana em Foco, 55).



Braz CF, Polivanov H, Chagas, CS, Carvalho-Júnior W, Barroso EV, Guerra AJT, Calderano SB. Artificial neural networks applied for soil class prediction in mountainous landscape of the serra do mar. R. bras. ci. solo. 2014; 38:1681-1693.

Camara G, Souza RCM, Freitas UM, Garrido J. SPRING: Integrating remote sensing and GIS by objectoriented data modeling. Computers & Graphics: New York; 1996. 20:395-403.

Cosme FCC. Árvores de decisão [internet]. Local: instituto; 2002 [acesso em 10 de jul de 2015]. Disponível em: <http://pt.scribd.com/doc/218178007/Arvores-de-decisao-doc>.

Cunningham S, Denize P. Dept. of computer science [internet]. New Zeland: Universit of Waikato; 1995 [acesso em 20 de ago de 2015]. Disponível em: <http://www.cs.waikato.ac.nz/ml/publications.html>.

Efron B, Gong G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. Washington: The American Statistician; 1983. 37:36-48.

Efron B, Tibshirani RJ. An Introduction to the Bootstrap. New York: Chapman & Hall; 1993.

FAO. Statistics Division. Food and Agriculture commodities production [internet]. Roma: Fao; 2013 [acesso em 06 de fev de 2016]. Disponível em: [http://faostat3.fao.org/browse/rankings/countries\\_by\\_commodity/S](http://faostat3.fao.org/browse/rankings/countries_by_commodity/S).

Fleiss JL. Statistical methods for rates and proportions, 2nd ed. New York: John Wiley & Sons, 1981.

Fonseca JA, Meurer EJ. Inibição da absorção de magnésio pelo potássio em plântulas de milho em solução nutritiva. Rev. bras. ciên. Solo. Campinas. 1997; 21:47-50.

Furlani PR, Silveira LCP, Bolonhezi D, Faquin V. Cultivo hidropônico de plantas. Campinas: IAC; 1999. (Boletim Técnico, 180).

Galen RS, Gambino SR. Beyond normality: The predictive value and efficiency of medical diagnosis. New York: J. Wiley & Sons; 1975.

Gomes JA. Absorção de nutrientes pela banana, cultivar Prata (*Musa* AAB, subgrupo Prata) em diferentes estádios de desenvolvimento [tese]. Piracicaba: ESALQ; 1988.

Haag HP, Minami K. Nutrição mineral de hortaliças: LXXV. Absorção de nutrientes pela cultura de almeirão. Anais da Escola Superior de Agricultura Luiz de Queiroz, 1998; 45:597-603.

Hawksford M, Horst W, Kichey T, Lambers H, Schjoerring J, Moller IS, White P. Functions of macronutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.135-189.

Haykin S. Neural networks and learning machines. 3rd ed. New York: Prentice Hall; 2009.

Haykin S. Neural Networks: A Comprehensive Foundation. New York: MacMillan, 1999.

Haykin S. Redes neurais: princípios e prática. Porto Alegre: Bookman; 2001.

Hoagland DR, Arnon DI. The water culture method for growing plants without soils. Berkeley: California Agricultural Experimental Station; 1950.

IBGE. Base de dados agregados [internet]. Brasília: instituto Brasileiro de Geografia e Estatística; 2016 [acesso em 06 fev de 2016]. Disponível em: <http://www.sidra.ibge.gov.br/bda/prevsaf/default.asp>.

Johnson RA, Wichern DW. Applied Multivariate Statistical Analysis, 5 ed. New Jersey: Prentice-Hall; 2002.

Kirkby E. Introduction, definition and classification of nutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.3-5.

Lahav E. Banana nutrition. In: Gowen S. ed. Bananas and plantains. London, Chapman & Hall; 1995. p.258-316.

- Malavolta E. Elementos de nutrição mineral de plantas. São Paulo: Agronômica Ceres; 1980.
- Malavolta EA, Manual de nutrição mineral de plantas. São Paulo: Agronômica Ceres; 2006.
- Marenco RA, Lopes NF. Fisiologia vegetal. 3<sup>a</sup> ed. Viçosa: Editora UFV; 2009.
- Martin-Prével P. Bananier. In: Martin-Prével P, Gagnard J, Gautier P. Editores. L'analyse végétale dans le contrôle de l'alimentation des plantes tempérées et tropicales. Paris: Tec&Doc; 1984. p.715-51.
- Mengel K, Kirkby EA. Principles of plant nutrition. 5<sup>th</sup> ed. Dordrecht: Kluwer Academic; 2001.
- Meurer EJ. Potássio. In: Manlio SF. Editor. Nutrição mineral de plantas. Viçosa: Sociedade Brasileira de Ciência do Solo; 2006. p.282-298.
- Montagut G, Martin-Prével P. Besoins en engrais des bananeraies antillaises. Fruits. Paris. 1965; 20:265-273.
- Monteiro FA, Ramos AKB, Carvalho DD, Abreu JBR, Daiub JAS, Silva JEP, Natale W. Cultivo de *Brachiaria brizantha* stapf. Cv. Marandu em solução nutritiva com omissões de macronutrientes. Sci. Agric. Piracicaba. 1995; 52:135-141.
- Novais RF, Smyth TJ, Nunes FN. VII – Fósforo. In: Novais RF, Alvarez VH, Barros NF, Fontes RL, Cantarutti RB, Neves JCL. editores. Fertilidade do solo. Viçosa: Sociedade Brasileira de Ciência do Solo; 2007. p.92-120.
- Paiva EAS, Sampaio RA, Martinez HEP. Composition and quality of tomato fruit cultivated in nutrient solutions containing different calcium concentration. Journal of plant nutri. Philadelphia. 1998; 21:2653-2661.
- Paiva R, Oliveira LM. Fisiologia e produção vegetal. Lavras: Editora UFLA; 2006. 104.

Perrier X, Bakry F, Carreel F, Jenny C, Horry JP, Lebot V, Hippolyte I. Combining biological approaches to shed light on the evolution of edible bananas. *Ethnobot. research and applications*. Fort Worth. 2009; 7:199-216.

Pestana M, Varennes A, Faria EA. Diagnosis and correction of iron chlorosis in fruit trees: a review. *Food Agric. Environ*. 2003; 1:46-51.

Prado RM. 500 perguntas e respostas sobre nutrição de plantas. 1. ed. Jaboticabal: FCAV/GENPLANT; 2009.

Sena-Júnior DG, Pinto FAC, Gomide LA, Teixeira MM. Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por *Spodoptera frugiperda*. *Rev. Bras. Eng. Agríc. Ambiental*; 2003. 7:359-366.

Siddiqi MY, Glass ADM. Utilization index: a modified approach to the estimation and comparison of nutrient efficiency in plants. *Journal of plant nutr.* Monticello. 1981; 4:289-302.

Silva JTA, Carvalho JG. Avaliação nutricional de bananeira Prata-Anã (AAB), sob irrigação no semi-árido do norte de Minas Gerais, pelo método Dris. *Ci. Agrotecnologia*, Lavras. 2005; 29:731-739.

Soares FAL, Gheyi HR, Oliveira FHT, Fernandes PD, Alves NA, Silva FV. Acúmulo, exportação e restituição de nutrientes pelas bananeiras “Prata Anã” e “Grand Naine”. *Ci Rural*. 2008; 38:2054-2058.

Teixeira LAJ, Spironello A, Quaggio JA, Furlani PR. Banana. In: Raij B, Cantarella H, Quaggio JÁ, FUrlani AMC. Editores. *Recomendações de adubação e calagem para o Estado de São Paulo*. Campinas: Fundação IAC; 1997. p.131–132. (Boletim, 100).

Tourian OK, Padilha FRR. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. *Eng. agríc.* Jaboticabal. 2008; 28:759-769.

Turner DW, Barkus, B. Loss of mineral nutrients from banana pseudostems after harvest. *Trop. Agriculture*. 1973; 50:229-233.

Vale DW, Prado RM, Avalhães CC, Hojo RH. Omissão de macronutrientes na nutrição e no crescimento da cana-de-açúcar cultivada em solução nutritiva. *Rev. bras. ciênc. Agrár. Recife*. 2011; 6:189-196.

Varella CAA, Pinto FAC, Queiroz DM, Sena-Júnior DG. Determinação da cobertura do solo por análise de imagens e redes neurais. *Ver. Bras. Eng. Agríc. Ambiental*. 2002; 6:225-229.

Venkatesh YV, Raja S. On the classification of multispectral satellite images using the multilayer perceptron. *Pattern Recognition*. 2003; 36:2161-2175.

Venturini MT, Santos LR, Oliveira EJ. Development of a diagramatic scale for the evaluation of postharvest physiological deterioration in cassava roots. *Pesq. Agropec. Bras. Brasília*. 2015; 50:658-668. Doi: 10.1590/S0100-204X2015000800004

## **CAPÍTULO 2. VALIDAÇÃO DE CAMPO DO PROCESSAMENTO DIGITAL DE IMAGENS PARA IDENTIFICAÇÃO DE DEFICIÊNCIAS DE CÁLCIO E MAGNÉSIO NA CULTURA DA BANANA**

### **RESUMO**

Na bananicultura é rotineiro o uso de uma intensa adubação potássica visando atender a alta demanda deste nutriente pela cultura. Os excessos de potássio aliado a um manejo inadequado da calagem podem reduzir a concentração de cálcio e magnésio no solo, gerando um desbalanço destes cátions que acarretará em deficiências nutricionais muitas vezes irreparáveis no mesmo ciclo produtivo. Visando diagnosticar precocemente deficiências de cálcio e magnésio na bananeira foi realizado um experimento em área com baixas concentrações destes elementos, com doses crescentes de calcário, que variaram de 0 a 13,82 t h<sup>-1</sup>. No 2º ciclo produtivo foram colhidas e obtidas imagens digitais das folhas índices das plantas e posteriormente analisados seus teores nutricionais. As imagens foram classificadas por redes neurais artificiais quanto ao nível de deficiência de cálcio e/ou magnésio que apresentariam com base em um base de dados de deficiências nutricionais obtido em solução nutritiva com omissão de nutrientes. Os resultados obtidos demonstraram comportamentos distintos na absorção de cálcio e magnésio pela cultura, onde ocorreu o aumento os teores de Ca com o aumento das doses, o mesmo não sendo notado para Mg. A rede neural obteve baixa taxa de acerto em identificar as imagens quanto às doses do tratamento correspondente, entretanto, considerando as classes da base de dados gerados em sistema com omissão de nutrientes, a rede neural demonstrou que as amostras obtidas nas menores doses de calcário utilizadas foram semelhantes à classe omissão de cálcio e magnésio e, à medida que as doses de calcário aumentaram, as amostras foram agrupadas na classe solução nutritiva completa, demonstrando a capacidade da rede neural em identificar possíveis sinais de deficiências destes elementos.

Palavras-Chave: Redes neurais artificiais. Bananicultura. Deficiência de cálcio. Deficiência de magnésio. Calcário.

## **CHAPTER 2. FIELD VALIDATION OF DIGITAL IMAGES PROCESSING FOR IDENTIFICATION OF CALCIUM AND MAGNESIUM DEFICIENCIES IN BANANA CROPS**

### **ABSTRACT**

In banana crops are common to use intense potassic fertilization to meet the high demand of this nutrient for culture. The K excesses ally an inappropriate liming management may reduce the calcium and magnesium concentration in soil, create disbalance of those cations which carries in irrecoverable nutritional deficiencies in the same production cycle. Aiming to diagnose premature deficiency of calcium and magnesium in banana plants was realized an experiment in area with low concentration those elements, with increasing doses of limestone, ranging from 0 to 13,82 t ha<sup>-1</sup>. In the second production cycle were harvested and obtained digital images of index leafs and after that analyzed the nutritional contents in laboratory. The images were classifieds according to their nutritional deficiency level of calcium and/or magnesium by Artificial Neural Networks (ANNs) based on a database of nutritional deficiencies acquired in nutritional solution with nutrients omission. The results showed different behaviors in the uptake of calcium and magnesium by plant, occurring the increasing of Ca contents with increased doses of limestone, that was not observed with Mg. The ANN obtained low hit rates when tried to identify the images as their corresponding treatment doses. However, considering the databases classes generated in nutritional omission system, the ANN showed that the samples in the smaller doses of limestone were similar to calcium+magnesium omission class, and as the limestone doses were increasing, the samples were grouped in complete nutritional solution class, showing the capacity of ANNs to identify possible signs of deficiencies those elements.

Key-Words: Artificial neural networks. Banana cultivation. Calcium deficiency. Magnesium deficiency. Limestone.

## 2.1. INTRODUÇÃO

Na bananicultura é comum a preocupação constante dos produtores com a adequada nutrição de potássio, visto ser o nutriente absorvido em maior quantidade pela bananeira (Lopez e Espinosa, 1995). Não obstante, é fato que muitas vezes cálcio e magnésio são pouco valorizados neste balanço (Silva e Carvalho, 2005; Silva et al., 2008), quer seja pela negligência na prática da calagem ou pelo equívoco no desbalanço de potássio em detrimento a estes cátions (Borges, 2004).

Cálcio e magnésio são macronutrientes essenciais para as plantas (Hawksford et al., 2012). Para a cultura da bananeira estes elementos são necessários em quantidades e épocas diferenciadas (Teixeira et al., 2008), contudo seu aporte ao solo ocorre, na maioria das vezes, via aplicações de calcário (Quaggio et al., 1997).

O cálcio é necessário durante todo o período vegetativo, visto sua importância estrutural na sustentação da copa principalmente, e também na formação e enchimento de fruto. Já o magnésio, essencial no processo fotossintético, assume grande importância no período vegetativo, com incremento no acúmulo a partir de 180 dias (Gomes et al., 1998).

As deficiências destes nutrientes possuem características distintas. Entretanto, por seu aporte ao solo ser feito de maneira conjunta, a falta ou desbalanço destes elementos em razão de outros, principalmente o potássio, também ocorre com mais frequência conjuntamente (Gomes et al., 2002).

A identificação de deficiências nutricionais ou mesmo a incidência de pragas e doenças de plantas, na maioria das vezes, pode ser realizada por uma pessoa capacitada, *in loco* ou com auxílio de uma análise laboratorial da planta ou parte dela (Munson e Nelson, 1973).

Recentemente, outros modos de identificação de características e distúrbios em plantas vêm se difundindo. Estes modos utilizam ferramentas computacionais e, geralmente, estão aliados ao uso de imagens digitais que passam por algum tipo de processamento.

Sena-Junior et al. (2003) utilizando redes neurais artificiais identificou o ataque de lagarta do cartucho em imagens de campo. Khatchatourian e Padilha (2008) realizaram a identificação de oito variedades diferentes de soja a partir de imagens das sementes. Silva (2008) utilizou redes neurais na identificação de estádios iniciais de Sigatoka Negra em bananeiras. Chagas et al. (2009) realizou a identificação de níveis de degradação de pastagens com uso de visão artificial aliada a redes neurais artificiais. Oliveira et al. (2013) realizaram o mapeamento de fragmentos florestais de Aroeira, uma espécie em extinção.



Considerando a eficiência das redes neurais artificiais e seu potencial de aplicação na agricultura e os poucos trabalhos na área de nutrição de plantas, este trabalho objetivou avaliar a eficiência das redes neurais artificiais na identificação de deficiências de cálcio e magnésio em bananeiras de 2º ciclo produtivo através de imagens de folhas a partir de uma base de dados de deficiências concebidas e previamente estabelecida.

## 2.2. MATERIAL E MÉTODOS

### 2.2.1. CAMPO

A fim de observar as deficiências de Ca e Mg foi instalado um experimento dentro de um talhão comercial da cultivar Grande Naine, no município de Registro-SP, o experimento encontrava-se à Latitude de 24° 27' 2" S e Longitude de 47° 49' 27" W, e a experimentação à campo ocorreu em paralelo ao experimento proposto.

O delineamento empregado foi em blocos casualizados com cinco doses de calcário, com quatro repetições, empregando a 'Grande Naine', mesma variedade utilizada na experimentação, em casa de vegetação (Capítulo 1).

Anterior à instalação do experimento realizou-se uma amostragem composta, decorrente da coleta de 20 amostras simples, para determinação dos atributos químicos do solo da área experimental (TABELA 1).

TABELA 1. Análise química do solo coletado na área, a ser instalado o experimento na Fazenda Arapongá nas camadas de 0-20 e 20-40 cm de profundidade.

Prof.	pH	M.O.	P	K	Ca	Mg	H+Al	SB	T	V
cm	CaCl <sub>2</sub>	g/dm <sup>3</sup>	mg/dm <sup>3</sup>	----- mmol <sub>c</sub> /dm <sup>3</sup> -----						%
00-20	4,6	54	14	1,9	15	9	58	25,9	83,9	31
20-40	4,1	17	2	0,5	4	2	80	6,5	86,5	8

Prof.	B	Cu	Fe	Mn	Zn	S-SO <sub>4</sub>	Al	Argila	Areia
cm	----- mg/dm <sup>3</sup> -----			----- mmol <sub>c</sub> /dm <sup>3</sup> -----				%	
00-20	0,58	0,1	93	2,9	2,1	4	4	30	54
20-40	0,28	0,2	74	0,1	0,2	4	16	29,7	50,3

As doses de calcário foram calculadas considerando-se os resultados médios da análise química das camadas de 0–20 e 20–40 cm (TABELA 1) e, também, ajustando-se as doses para incorporação do calcário na camada de 0–30 cm de profundidade (Natale et al., 2007). Tomou-se como referência a dose calculada para atingir a saturação por bases (V) igual a 60

% (6,91 t/ha), recomendada para a bananeira no estado de São Paulo (Teixeira et al., 1997) e, a partir desta, como segue: D0 = zero; D1 = metade da dose; D2 = dose total; D3 = 1,5 vez a dose; e D4 = duas vezes a dose necessária para elevar V a 60 %, correspondendo a: 0; 3,46; 6,91; 10,37; e 13,82 t ha<sup>-1</sup>, em decorrência ao emprego do calcário utilizado (TABELA 2).

TABELA 2. Resultados analíticos de amostra de calcário empregado na implantação do experimento.

Parâmetros	Unidade	Resultado
Cálcio (como óxido)	% de CaO (m/m)	29,8
Magnésio (como óxido)	% de MgO (m/m)	20,3
Cálcio	% de Ca (m/m)	21,3
Magnésio	% de Mg (m/m)	12,7
Poder de Neutralização (PN)	% de CaCO <sub>3</sub> eq.	100,5
Poder Relativo de Neutralização Total (PRNT)	%	74,9

O calcário foi aplicado ao solo em janeiro de 2013 e, após seis meses, foi implantado o pomar (julho/2013), utilizando-se mudas micropropagadas de bananeiras ('Grande Naine' Williams).

O calcário foi aplicado manualmente em toda a superfície do terreno, metade antes da incorporação com arado de aivecas e a outra metade aplicada e incorporada com grade aradora e posteriormente com grade niveladora. O implemento, arado de aivecas, abrangeu a camada de 0–30 cm, já a grade aradora abrangeu cerca de 0–18 cm.

Transcorridos seis meses e imediatamente antes da abertura das covas foi aplicado 125 kg ha<sup>-1</sup> de P<sub>2</sub>O<sub>5</sub>, ou seja, 50 % da dose recomendada, em área total, como superfosfato triplo e incorporado com grade niveladora. A adubação básica na cova de plantio constou da mistura de 224 g de P<sub>2</sub>O<sub>5</sub> na forma de superfosfato triplo granulado, além de 1,5 g de B e 2,5 g de Zn, na forma de ácido bórico e de sulfato de zinco, respectivamente, como recomendado por Teixeira et al. (2007) e Nomura et al. (2011) e observado a análise de solo (TABELA 1).

O plantio das mudas ocorreu no espaçamento de 2,5 m entre linhas x 2,0 m entre plantas, resultando numa população de 2.000 plantas ha<sup>-1</sup>. As parcelas experimentais foram compostas por quatro linhas de seis plantas cada, totalizando 24 plantas, sendo consideradas as quatro plantas centrais como úteis para as avaliações e por linhas de bordadura de ambos os lados.

A área experimental não possuía irrigação, como ocorre em quase toda a totalidade dos plantios de banana no Vale do Ribeira.

A adubação de implantação e produção seguiu as indicações de Teixeira et al. (1997, 2007a, 2007b, 2008), para a cultura da bananeira, considerando-se a fertilidade do solo. O parcelamento das doses, bem como a localização de aplicação dos fertilizantes, atendeu às recomendações dos mesmos autores, empregando-se como fontes: nitrato de amônio, superfosfato triplo e cloreto de potássio.

O plantio e os tratos culturais realizados no manejo do bananal seguiram as recomendações de Moreira (1987; 1999). Salienta-se que, o manejo do bananal seguiu as recomendações técnicas para a região, destacando-se que o controle de Sigatoka está sendo realizado de forma preventiva, com aplicações aéreas de fungicidas.

No segundo ciclo produtivo foram coletadas 12 subamostras de solo por parcela, na camada de 0-20 cm, para constituir uma amostra composta e determinar o efeitos dos tratamentos nas características químicas do solo. Para isso, utilizou-se como auxílio o trado tipo holandês. As determinações analíticas, seguiram os métodos descritos por Raij et al. (2001). Também foram avaliadas as folhas índices para avaliação do estado nutricional das plantas, a qual ocorreu por meio da análise química do limbo foliar do terço médio nas quatro plantas da área útil, da terceira folha, contada a partir do ápice, amostrada na época da emissão floral (Martin-Prével, 1984) nas quatro plantas da área útil. Os teores de nutrientes foram determinados como indicam Bataglia et al. (1983).

Os resultados obtidos foram submetidos ao teste F, e quando este foi significativo ( $p < 0,05$ ), as médias dos tratamentos foram comparadas pelo teste de Tukey ( $p < 0,05$ ) e por análise de regressão, quando necessário.

### 2.2.2. COMPUTACIONAL

Realizou-se um experimento computacional para identificação dos sintomas de deficiências nutricionais a partir dos padrões encontrados para estas deficiências nas folhas índices coletadas para cada um dos tratamentos. Tais padrões visaram à identificação dos teores de cálcio e magnésio a partir dos tratamentos, ou seja, das diferentes doses de calcário aplicadas. Para tanto, foi utilizado o processamento digital de imagens, composto por quatro fases distintas de operacionalização: coleta e digitalização das amostras, segmentação e extração dos histogramas das imagens, seleção de atributos e, por último, classificação.

Ao se coletar e identificar as folhas índices coletadas no experimento realizado a campo, as mesmas foram imediatamente levadas ao laboratório do CERE da Unesp, para digitalização, que ocorreu com auxílio de scanner de mesa (HP G2410®), com resolução de 600 dpi. As folhas separadas e classificadas de acordo com seu respectivo tratamento. De

cada folha foi gerada uma imagem e de cada imagem foram extraídas 20 subamostras, com auxílio do software GIMP®, com dimensões de 100 x 100 pixels, totalizando 400 subamostras (5 doses x 4 blocos x 20 subamostras). A cada subamostra foi atribuída uma classe correspondente ao seu tratamento (D0 a D4).

Cada subamostras foi segmentada nos três componentes do sistema de cores RGB (*red green e blue*) com 256 tons de cinza, de cada componente foram extraídos histogramas da distribuição de pixels na escala de cinza variando de 0 a 255, sendo 0 preto puro e 255 branco puro, com auxílio do software SPRING (Camara et al., 1996). Os histogramas, gerados em arquivos de texto puro (.txt), foram compilados em planilha eletrônica de forma que cada linha representou uma subamostra formando um base de dados.

A base de dados formada consistiu de 400 linhas, referentes ao número de subamostras, onde cada linha conteve 769 variáveis, sendo 768 variáveis de entrada compostas pela frequência de cada nível de cinza para cada componente do sistema RGB [256\*3] e uma variável de saída correspondente à classificação original da amostra de acordo com o tratamento aplicado.

A base de dados foi submetida ao software WEKA (Cunningham e Denize, 1995), onde a análise multivariada de seleção de componentes principais visou diminuir expressivamente o número de variáveis de entrada substituindo-as por componentes principais selecionadas quanto ao grau de importância na classificação dos sintomas, sem prejuízo da informação biológica contida na variabilidade das respostas (Johnson e Wichem, 2002).

Por fim, para a classificação dos padrões coletados utilizou-se a técnica de Redes Neurais Artificiais (RNA). A de RNA utilizada foi a Perceptron multicamadas, treinadas com o algoritmo *backpropagation*, utilizando-se os valores de 0,2 para as taxas de aprendizado e de 0,3 para o termo momentum (Haykin, 1999). Nesta etapa também foi utilizado ao software WEKA.

Para obter uma estimativa não viciada de erro do classificador, utilizou-se de técnicas de amostragem para manipulação dos conjuntos de treinamento e teste. Neste trabalho, foi considerada a metodologia r-partição *cross-validation* (Efron e Gong, 1983; Efron e Tibshirani, 1993), que divide o conjunto de dados total, de tamanho  $n$ , em  $r$  partes mutuamente exclusivas (partições) de tamanhos iguais a  $n/r$  amostras. As amostras nos  $(r - 1)$  partições são usadas para treinamento e a hipótese induzida é testada na partição remanescente. Este processo é repetido  $r$  vezes, cada vez considerando uma partição diferente para teste. O erro no *cross-validation* é a média dos erros calculados em cada um dos  $r$  partições de teste (Baranauskas, 2000).

Para todos os testes realizados pelo classificador, a rede neural contou com a mesma configuração, sendo ela 38 componentes principais, compondo os valores de entrada, 25 nós (neurônios) e três camadas.

Para verificar a consistência e confiabilidade dos resultados foi observada a taxa de erro do classificador, taxa de acerto do classificador, raiz quadrada do erro médio e as percentagens de acerto para cada classificação (Sena-Júnior et al., 2003).

A fim de atingir os objetivos propostos realizou-se um experimento em casa de vegetação (Capítulo 1) para determinar os padrões característicos de deficiências nutricionais. Posteriormente, procurou-se realizar a validação desse experimento em casa de vegetação.

Os padrões obtidos no experimento em casa de vegetação (Capítulo 1) foram utilizados na validação da sintomatologia observada neste experimento, a fim de verificar a consistência e confiabilidade dos padrões obtidos em experimentos de indução de deficiência em ambiente controlado com os que são apresentados em áreas comerciais de cultivo.

## 2.3. RESULTADOS E DISCUSSÃO

### 2.3.1 CAMPO

As doses de calcário aplicadas (tratamentos) se apresentaram significativas para a maioria das variáveis avaliadas no solo, de acordo com a TABELA 3.

TABELA 3. Valores de F da ANOVA dos atributos químicos do solo.

ANOVA dos fatores químicos do solo avaliados (0-20 cm)									
Fonte de Variação	M.O.	pH	P	K	Ca	Mg	Al	H+Al	SB
Dose	*	**	**	ns	**	**	**	**	**
Bloco	ns	ns	ns	ns	ns	ns	ns	ns	ns
F	3,2	20,6	9,3	2,1	34,2	55,6	194,3	74,6	42,4
C.V. (%)	7,6	6,3	17,3	24,3	13,7	13,9	28,0	12,7	12,8

Fonte de Variação	CTC	V%	S	B	Cu	Fe	Mn	Zn
Dose	**	**	ns	ns	**	**	**	**
Bloco	ns	ns	ns	ns	ns	ns	ns	ns
F	5,8	120,7	0,6	2,7	26,5	84,0	14,7	19,8
C.V. (%)	8,7	6,9	19,2	26,7	13,6	15,8	19,4	19,9

\*\*, \*; ns: significativo a  $p < 0,05$ ; a  $p < 0,01$  e não significativo, respectivamente.

A área experimental utilizada era apropriada ao estudo de calagem, visto que os atributos químicos (TABELA 1) de acidez são considerados *Altos* na camada de 0-20 cm de

profundidade como preconiza Raij et al. (1997), para culturas em geral para o Estado de São Paulo.

O comportamento de decréscimo dos micronutrientes Fe, Cu, Mn e Zn, bem como o aumento dos teores de Ca, Mg e P com o aumento do pH já é conhecido na literatura devido à aplicação do calcário (Malavolta, 1979; Mengel e Kirkby, 1987; Natale et al., 2007) (FIGURA 1A, B, C e D).

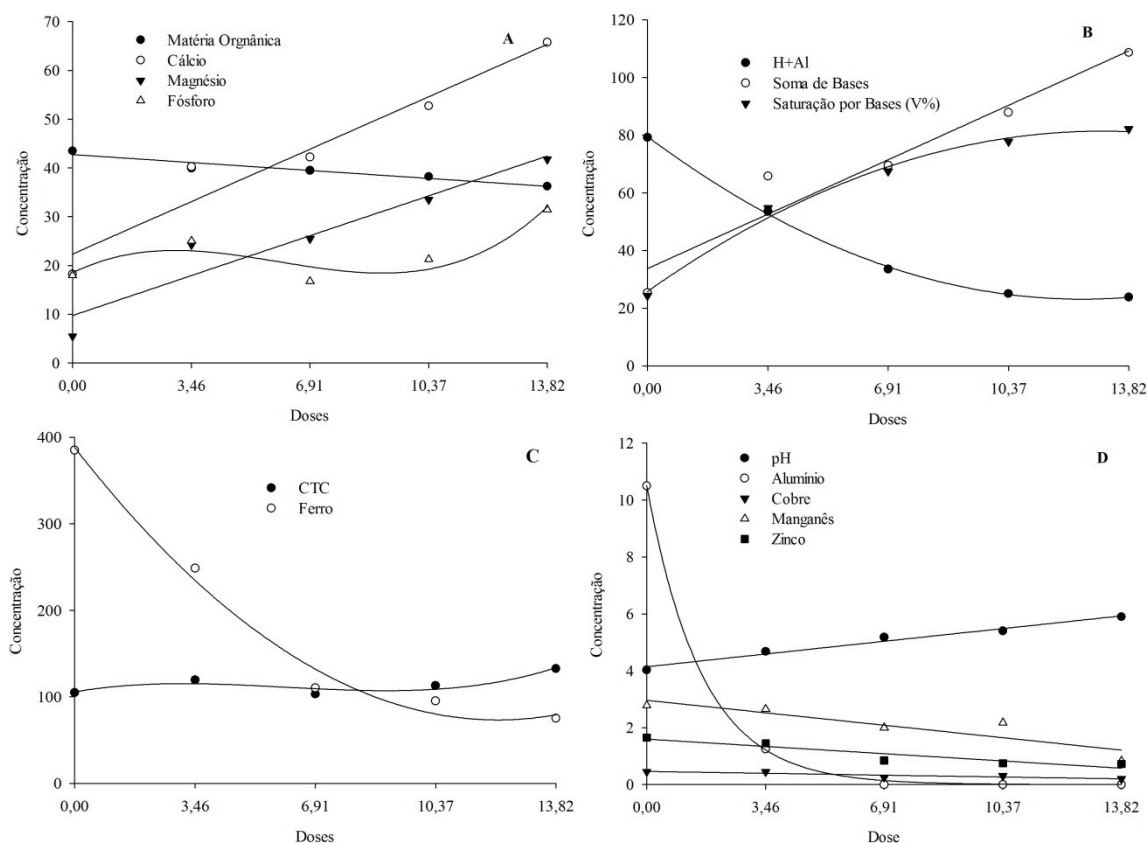


FIGURA 1. Efeito das doses de calcário ( $t\ ha^{-1}$ ) sobre os fatores químicos do solo avaliados (0-0,2 m).

A concentração de K manteve-se constante a  $1,49\ mmol_c\ dm^{-3}$ , demonstrando que as indicações de adubação preconizada por Teixeira et al. (1997, 2007a, 2007b, 2008) foram suficientes para manter o nível da fertilidade inicial, bem como não houve competição entre as bases do solo, mesmo considerando as elevadas doses utilizadas de calcário nos tratamentos D2, D3 e D4.

A concentração de Al no solo chegou a zero a partir da dose de  $10,5\ t\ ha^{-1}$ , com ajuste exponencial negativo. A matéria orgânica sofreu redução na sua concentração, devido ao estímulo à atividade microbiana, resultando na decomposição dos tecidos vegetais e oxidação

da matéria orgânica do solo por efeito do calcário e revolvimento do solo na implantação (Silva, 2014) (TABELA 4 e FIGURA 1A).

TABELA 4. Equação, valor de F e coeficientes de determinação do efeito das doses de calcário sobre os fatores químicos do solo avaliados (0-0,2 m).

Fatores	Equação	F	R <sup>2</sup>
M.O., g dm <sup>-3</sup>	$y=42,75-1,62x$	42,23**	0,93
pH, CaCl <sub>2</sub>	$y=4,14+0,45x$	124,67**	0,97
P, mg dm <sup>-3</sup>	$y=18,49+3,44x-0,76x^2+0,04x^3$	2,37 <sup>ns</sup>	0,88
Ca, mmol <sub>c</sub> dm <sup>-3</sup>	$y=22,35+10,75x$	46,80**	0,94
Mg, mmol <sub>c</sub> dm <sup>-3</sup>	$y=9,75+8,17x$	33,68**	0,92
Al, mmol <sub>c</sub> dm <sup>-3</sup>	$y=10,5e^{-2,15x}$	11882,39**	0,99
H+Al, mmol <sub>c</sub> dm <sup>-3</sup>	$y=79,54-31,23x+4,32x^2$	1334,97**	0,99
SB, mmol <sub>c</sub> dm <sup>-3</sup>	$y=33,69+18,87x$	42,09**	0,93
CTC, mmol <sub>c</sub> dm <sup>-3</sup>	$y=105,62+23,76x-17,72x^2+3,38x^3$	2,14 <sup>ns</sup>	0,86
V, %	$y=25,76+29,43x-3,89x^2$	112,46**	0,99
Cu, mg dm <sup>-3</sup>	$y=0,46-0,06x$	11,79*	0,79
Fe, mg dm <sup>-3</sup>	$y=388,39-179,11x+25,44x^2$	75,11*	0,99
Mn, mg dm <sup>-3</sup>	$y=2,96-0,44x$	11,85*	0,80
Zn, mg dm <sup>-3</sup>	$y=1,59-0,25x$	19,65*	0,88

\*\*,\*, ns: significativo a  $p<0,05$ ; a  $p<0,01$  e não significativo, respectivamente.

A soma de bases (SB) apresentou ajuste linear crescente sobre efeito da calagem, e a saturação por bases (V%) ajuste quadrático, demonstrando que a dose calculada atingiu o V% esperado e as doses mais altas de calcário não atingiram os valores de V% correspondentes a elas.

O ponto máximo da equação quadrática para a saturação de bases foi de 26,16 t ha<sup>-1</sup> de calcário, entretanto, a saturação máxima atingida no experimento foi de 82 %, correspondente a dose de 13,82 t ha<sup>-1</sup> (TABELA 4). Observou-se que, mesmo havendo elevação da V% pela calagem a saturação por bases pretendida pelo cálculo (Quaggio et al., 1997) não foi alcançada pelas doses auferidas. A literatura aponta alguns fatores como responsáveis por isso, como o deslocamento da reação de equilíbrio da solubilização do corretivo e a interação de Ca e Mg com outros elementos formando novos minerais pouco solúveis, como hidróxidos (Natale et al., 2007) .

Da Silva et al. (2007), avaliando os atributos químicos do solo em cultivos de baixa, média e alta produtividade demonstraram que, os bananais de maiores produtividades obtiveram V% média de 83. Isso demonstra que, a cultura da bananeira com o passar dos anos e a seleção de novos genótipos, apresenta hoje uma necessidade maior de saturação por bases, de modo a sustentar uma produção de cachos maiores e mais pesados e com maior extração e exportação de nutrientes.

Para os teores foliares, os tratamentos aplicados apresentaram significância apenas para as variáveis cálcio (Ca), cobre (Cu), manganês (Mn) e zinco (Zn) (TABELA 5).

TABELA 5. Valores de F da ANOVA dos teores foliares

Teores	N	P	K	Ca	Mg	S
F	2,27ns	0,37ns	0,34ns	7,35**	1,66ns	1,85ns
C.V. (%)	3,52	7,12	5,97	10,41	12,38	6,62
	B	Cu	Fe	Mn	Zn	
F	0,47ns	3,56*	0,55ns	19,69**	4,23*	
C.V. (%)	18,36	19,11	28,18	34,83	5,66	

\*significativo a  $p < 0,05$ , ns: não significativo.

Os teores de Ca apresentaram aumento, em sua maioria, com o aumento das doses de calcário (FIGURA 2A). O comportamento estático no teor de Mg indica um mecanismo diferenciado de seletividade deste cátion pela cultura, se comparado ao Ca, já que, para ambos, houve aumento na concentração no solo face à elevação das doses de calcário. Genú (1976), indica, corroborando com o presente estudo, que na cultivar Prata houve variações nos teores foliares durante o crescimento das plantas, exceto para Mg que permaneceu constante.

Os teores foliares de Cu, Mn e Zn apresentaram comportamento decrescente refletindo o comportamento destes elementos no solo com a elevação do pH provocado pelo aumento das doses de calcário (FIGURA 2B). Observamos assim que dos elementos afetados pelo pH, estes micronutrientes, e o Al foram os mais sensíveis à calagem, entretanto, não foram observados sinais de deficiência de micronutrientes durante a condução do experimento.

Borges et al. (2006), avaliando o comportamento do teor foliar de 24 genótipos de banana obteve valores semelhantes aos encontrados neste experimento para a ‘Grande Naine’ dos nutrientes P, K, Fe e S. As Doses D1 e D3 apresentaram valores semelhantes de Ca. Os teores de N e Mn estavam abaixo dos encontrados para o genótipo deste estudo, e os teores de Mg, B e Cu apresentaram valores superiores. Já de acordo com a recomendação para



bananeira irrigada (Wichmann, 1992), tem-se apenas K, B, Cu, Mn e Zn abaixo das faixas consideradas ideais.

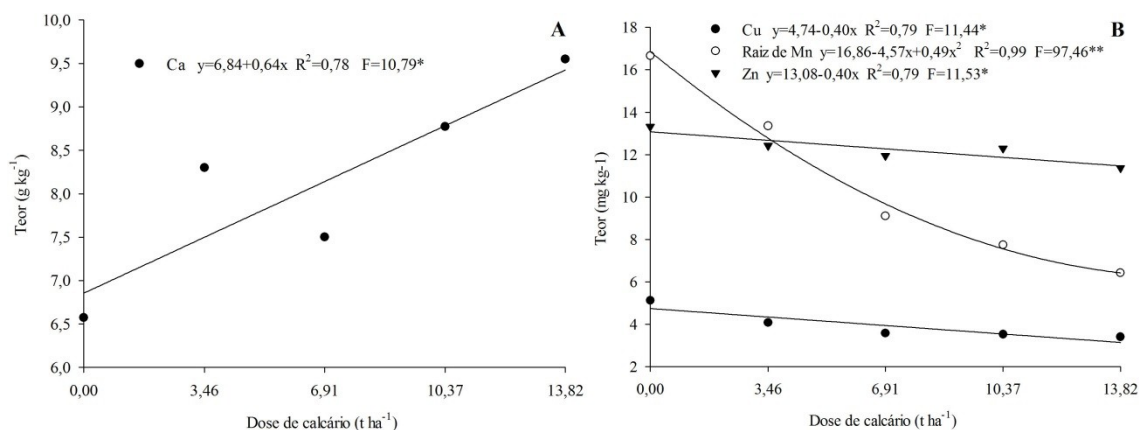


FIGURA 2. Equações, coeficiente de determinação e F do efeito das doses de calcário aplicadas sobre os teores foliares de cálcio (A) e micronutrientes (B) (\*\* e \*: significativo a  $p<0,01$  e  $0,05$ ).

### 2.3.2. COMPUTACIONAL

Os dados de campo resultaram na matriz de confusão apresentada na TABELA 6, onde n representa o número de amostras (Origem) classificadas em cada tratamento (Destino) totalizando ao final 80 amostras para cada tratamento [4 repetições x 20 subamostras], e o quanto estes valores representam porcentagem (%). A diagonal destacada o acerto do classificador, gerado pela rede neural, em alocar as amostras (Origem) em suas respectivas classificações (Destino).

A matriz de confusão gerada pelo classificador com os resultados médios dos conjuntos de teste da base de dados de campo obteve uma taxa média de acerto de 28,5 %. O tratamento D0 foi o que obteve o maior acerto dentre as classes (36,3 %), seguido do tratamento D1 com 35 %. Observou-se que da D2, dose recomendada para a cultura, em diante, seguiram-se os menores resultados na classificação.

As doses a partir da D2 representam a dose de calcário adequada e acima da recomendada para a cultura, não sendo encontradas variações expressivas suficientes nas cores que permitissem uma distinção entre estas classes ou doses aplicadas. Assim, notou-se que houve uma identificação maior do classificador pelos tratamentos que possibilitaram o aparecimento de alguma sintomatologia de deficiência nutricional de cálcio e/ou magnésio, em comparação ao dos níveis de suficiência.

TABELA 6. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste das amostras obtidas à campo.

Origem		Destino					Total
		Dose 0	Dose 1	Dose 2	Dose 3	Dose 4	
Dose 0	n	29	20	10	12	9	80
	%	36,3	25,0	12,5	15,0	11,3	100
Dose 1	n	12	28	15	9	16	80
	%	15,0	35,0	18,8	11,3	20,0	100
Dose 2	n	22	17	16	15	10	80
	%	27,5	21,3	20,0	18,8	12,5	100
Dose 3	n	16	25	12	19	8	80
	%	20,0	31,3	15,0	23,8	10,0	100
Dose 4	n	10	30	11	7	22	80
	%	12,5	37,5	13,8	8,8	27,5	100

Não foi identificado nenhum efeito prejudicial das doses acima da recomendação para a cultura (D3 e D4), pois apesar da V% ultrapassar os 60 % recomendados não resultou em deficiências ou toxidez de micronutrientes observáveis.

Devido às altas taxas de erro das amostras nas classes (TABELA 6) e visando uma melhor identificação dos tratamentos, foram realizados testes de classificação com as classes (doses) pareadas. Com as taxas de acerto médias obtidas, foi criada uma matriz de modo a identificar se as doses mais distantes seriam mais bem classificadas do que as doses mais próximas entre si (TABELA 7).

TABELA 7. Matriz resultante da classificação (%) dos tratamentos em pares.

Origem	Destino				
	Dose0	Dose1	Dose2	Dose3	Dose4
Dose0	100,0	63,1	56,9	55,6	59,4
Dose1	-	100,0	63,1	62,5	58,9
Dose2	-	-	100,0	62,5	63,7
Dose3	-	-	-	100,0	62,5
Dose4	-	-	-	-	100,0

Foi observado que as doses mais próximos entre si apresentaram melhor distinção do que a comparação das doses distantes. Deste modo, o classificador não se mostrou capaz de distinguir e indicar, através dos atributos avaliados, as doses de calcário utilizadas, não sendo possível com isto, determinarmos a necessidade de calcário para a cultura a partir das imagens das folhas.

### 2.3.3. VALIDAÇÃO

Considerando a base de dados em casa de vegetação, no Capítulo 1 dessa dissertação, foi selecionado de cada nível de variação nutricional (Fator 1) apenas as amostras da época de coleta (Fator 2) que obteve a maior taxa de acerto, deste modo foi formado uma nova base de dados considerando: (i) a expressão do sintoma mais característica e (ii) o tempo necessário para a melhor expressão do sintoma. Assim, refutaram-se as amostras que possibilitariam uma maior confusão na classificação pelo classificador da rede (TABELA 8).

Com base na TABELA 8 observou-se que a expressão dos sintomas mais característicos e com maior distinção dos demais níveis de variação foram obtidos aos 60 dias para cálcio e cálcio + magnésio e 90 dias para magnésio. E para a distinção entre os métodos de cultivo (solo e solução) de 30 dias. O cálculo do tempo deu-se pelo tempo de cada tratamento somado 30 dias de acondicionamento prévio das plantas aos níveis de variação nutricional correspondentes.

TABELA 8. Taxa de acerto (%) do classificador para os conjuntos de teste de cada época de coleta (Fator 2) para cada nível de variação nutricional (Fator 1).

Variação nutricional	0 dias	30 dias	60 dias	90 dias	120 dias
Ca	53	70	48	35	50
Mg	38	55	83	45	40
Ca+Mg	33	72	50	45	57
Comp.	97	60	48	40	80
Solo	98	65	70	72	85

Com a seleção das amostras das melhores classificações, na TABELA 8, foi gerada uma nova base de dados com 300 subamostras [5 níveis de variação x 20 subamostras x 1 época de coleta x 3 repetições], que obteve os melhores resultados no conjunto de testes e classificação encontrados neste estudo (TABELA 9).

TABELA 9. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste para a base de dados da melhor época de classificação para cada classe, obtidos no experimento em casa de vegetação (Capítulo 1).

Origem	Destino					Total
	Ca	Mg	Ca+Mg	Comp.	Solo	

Ca (T30)	n	54	0	5	1	0	60
	%	90,0	0,0	8,3	1,7	0,0	100
Mg (T60)	n	0	58	0	1	1	60
	%	0,0	96,7	0,0	1,7	1,7	100
Ca+Mg (T30)	n	10	0	44	5	1	60
	%	16,7	0,0	73,3	8,3	1,7	100
Comp. (T0)	n	2	1	3	53	1	60
	%	3,3	1,7	5,0	88,3	1,7	100
Solo (T0)	n	0	1	1	0	58	60
	%	0,0	1,7	1,7	0,0	96,7	100

Após o treinamento e a aprendizagem com a nova base de dados, foram oferecidas à rede neural para classificação as amostras do experimento a campo, visando verificar a classificação das amostras obtidas no campo nas características dos tratamentos realizados no Capítulo 1 deste referido estudo.

A matriz de confusão dessa classificação obteve uma taxa média de acerto de 24,5 %, o que não significou um resultado negativo, apenas representou que os atributos do campo não correspondiam aos atributos da casa de vegetação, o que já era de se esperar, pois ambos advinham de tratamentos distintos (TABELA 10).

O mais importante a ser observado nesta matriz foi o agrupamento das amostras (linhas) dentro das classes avaliadas (colunas). O agrupamento das amostras nas classes desta matriz apresentou um comportamento totalmente diferenciado daquelas apresentadas até o momento, com as amostras distribuídas majoritariamente nas classes -Ca/Mg e Comp. (negrito).

Verifica-se na classificação que, os tratamentos do campo apresentaram um comportamento semelhante ao observado no tratamento em solução nutritiva completa, realizado em casa de vegetação, e também apresentaram uma tendência à deficiência de cálcio e magnésio correspondente ao tratamento omissão de cálcio e magnésio.

TABELA 10. Matriz de confusão dos resultados médios de classificação dos conjuntos de teste das amostras do experimento a campo (Origem) gerada a partir do aprendizado da base de dados das melhores épocas de avaliação para cada nível de variação nutricional do experimento em casa de vegetação (Destino).

Origem	Destino	Total
--------	---------	-------

		-Ca	-Mg	-Ca/Mg	Comp.	Solo	
Dose 0	n	1	2	26	51	0	80
	%	1,3	2,5	32,5	63,8	0,0	100
Dose 1	n	1	0	23	52	4	80
	%	1,3	0,0	28,8	65,0	5,0	100
Dose 2	n	4	0	13	55	8	80
	%	5,0	0,0	16,3	68,8	10,0	100
Dose 3	n	4	0	13	55	8	80
	%	5,0	0,0	16,3	68,8	10,0	100
Dose 4	n	4	0	13	55	8	80
	%	5,0	0,0	16,3	68,8	10,0	100

A FIGURA 3 mostra que a tendência das amostras em migrarem da classe Comp. para a classe -Ca/Mg diminuí a medida que as doses aumentaram e vice versa. Assim, quanto maior as doses de calcário aplicadas maior é a semelhança dos padrões de cores das amostras do campo com o tratamento em solução nutritiva completa. O tratamento D2 foi a dose em que as classes mais se aproximaram, pois houve um decréscimo na taxa de acerto da classe solução nutritiva completa concomitante ao aumento na taxa de acerto da classe omissão de cálcio e magnésio.

O resultado obtido foi considerado altamente satisfatório, tendo em vista a capacidade do classificador em indicar uma possível desordem para dois macronutrientes em meio ao grande número de fatores bióticos e abióticos que influenciam a cultura no campo, sendo uma opção de ferramenta a ser trabalhada para auxiliar na tomada de decisão do produtor.




FIGURA 3. Flutuação na taxa de acerto do classificador para as amostras de campo nas classes omissão de cálcio e magnésio (-Ca/Mg) e solução nutritiva completa (Comp.) para cada tratamento (dose de calcário).

## 2.4. CONCLUSÕES

1- As doses crescentes de calcário promoveram o aumento do pH e dos teores de fósforo, cálcio e magnésio, e a diminuição de alumínio, cobre, ferro, manganês e zinco no solo, no segundo ciclo produtivo.

2- As alterações nos teores de macro e micronutrientes no solo, em função das doses crescentes de calcário, refletiram-se no aumento dos teores foliares de cálcio, e diminuição dos teores de cobre, manganês e zinco.

3- Os tratamentos com doses mais próximas entre si foram mais bem distinguidos do que aqueles com doses mais distantes.

4- O classificador demonstrou que os tratamentos a campo se enquadraram nas classes Omissão de Cálcio e Magnésio (-Ca/Mg) e Solução Completa (Comp.), com tendência a migrarem da primeira (deficiente) para a segunda (sadia) a medida que as doses de calcário aumentaram.

## 2.5. LITERATURA CITADA

Almeida TBF, Prado RM, Flores RA, Politi LC, Barbosa JC. Avaliação nutricional do almeirão em soluções nutritivas suprimidas de macronutrientes. Scien. agrár. Paranaensis. 2013; 12:211-220.

Azeredo JA, Genú PYC, Aquino ARL, Campelo-Júnior JH, Rodriguez APM. Nutrição mineral e adubação da bananeira. In: Haag, HP Coord. Nutrição mineral e adubação de frutíferas tropicais do Brasil. 1ª ed. Campinas: Fundação Cargill; 1986. p.59-102.

Bagheri N, Ahmadi H, Alavipanah SK, Omid M. Multispectral remote sensing for site-specific nitrogen fertilizer management. Pesq. Agropec. Bras. Brasília. 2013; 48:1394-1401. doi: 10.1590/S0100-204X2013001000011

Baranauskas JA. Extração automática de conhecimento por múltiplos indutores [tese]. São Paulo: Instituto de Ciências Matemáticas e de Computação (USP); 2000.

Bataglia OC, Furlani AMC, Teixeira JPF, Furlani PR, Gallo JR. Métodos de análise química de plantas. Campinas: Instituto Agrônomo; 1983. (Boletim Técnico, 78)

Borges AL, Oliveira AMG, Souza, LS. Solos, nutrição e adubação. In: Alves EJ. editor. A cultura da banana: aspectos técnicos, socioeconômicos e agroindustriais. Brasília: Embrapa; 1999. p.197-260.

Borges AL. Interação entre nutrientes em bananeira. Cruz das Almas: Embrapa CNPMF; 2004. (Banana em Foco, 55).

Braz CF, Polivanov H, Chagas, CS, Carvalho-Júnior W, Barroso EV, Guerra AJT, Calderano SB. Artificial neural networks applied for soil class prediction in mountainous landscape of the serra do mar. R. bras. ci. solo. 2014; 38:1681-1693.

Camara G, Souza RCM, Freitas UM, Garrido J. SPRING: Integrating remote sensing and GIS by objectoriented data modeling. Computers & Graphics: New York; 1996. 20:395-403.

Cosme FCC. Árvores de decisão [internet]. Local: instituto; 2002 [acesso em 10 de jul de 2015]. Disponível em: <http://pt.scribd.com/doc/218178007/Arvores-de-decisao-doc>.

Cunningham S, Denize P. Dept. of computer science [internet]. New Zeland: Universit of Waikato; 1995 [acesso em 20 de ago de 2015]. Disponível em: <http://www.cs.waikato.ac.nz/ml/publications.html>.

Efron B, Gong G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. Washington: The American Statistician; 1983. 37:36-48.

Efron B, Tibshirani RJ. An Introduction to the Bootstrap. New York: Chapman & Hall; 1993.

FAO. Statistics Division. Food and Agriculture commodities production [internet]. Roma: Fao; 2013 [acesso em 06 de fev de 2016]. Disponível em: [http://faostat3.fao.org/browse/rankings/countries\\_by\\_commodity/S](http://faostat3.fao.org/browse/rankings/countries_by_commodity/S).

Fleiss JL. Statistical methods for rates and proportions, 2nd ed. New York: John Wiley & Sons, 1981.

Fonseca JA, Meurer EJ. Inibição da absorção de magnésio pelo potássio em plântulas de milho em solução nutritiva. Rev. bras. ciên. Solo. Campinas. 1997; 21:47-50.

Furlani PR, Silveira LCP, Bolonhezi D, Faquin V. Cultivo hidropônico de plantas. Campinas: IAC; 1999. (Boletim Técnico, 180).

Galen RS, Gambino SR. Beyond normality: The predictive value and efficiency of medical diagnosis. New York: J. Wiley & Sons; 1975.

Gomes JA. Absorção de nutrientes pela banana, cultivar Prata (*Musa* AAB, subgrupo Prata) em diferentes estádios de desenvolvimento [tese]. Piracicaba: ESALQ; 1988.

Haag HP, Minami K. Nutrição mineral de hortaliças: LXXV. Absorção de nutrientes pela cultura de almeirão. Anais da Escola Superior de Agricultura Luiz de Queiroz, 1998; 45:597-603.

Hawksford M, Horst W, Kichey T, Lambers H, Schjoerring J, Moller IS, White P. Functions of macronutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.135-189.

Haykin S. Neural networks and learning machines. 3rd ed. New York: Prentice Hall; 2009.

Haykin S. Neural Networks: A Comprehensive Foundation. New York: MacMillan, 1999.

Haykin S. Redes neurais: princípios e prática. Porto Alegre: Bookman; 2001.

Hoagland DR, Arnon DI. The water culture method for growing plants without soils. Berkeley: California Agricultural Experimental Station; 1950.



IBGE. Base de dados agregados [internet]. Brasília: instituto Brasileiro de Geografia e Estatística; 2016 [acesso em 06 fev de 2016]. Disponível em: <http://www.sidra.ibge.gov.br/bda/prevsaf/default.asp>.

Johnson RA, Wichern DW. Applied Multivariate Statistical Analysis, 5 ed. New Jersey: Prentice-Hall; 2002.

Kirkby E. Introduction, definition and classification of nutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.3-5.

Lahav E. Banana nutrition. In: Gowen S. ed. Bananas and plantains. London, Chapman & Hall; 1995. p.258-316.

Malavolta E. Elementos de nutrição mineral de plantas. São Paulo: Agronômica Ceres; 1980.

Malavolta EA, Manual de nutrição mineral de plantas. São Paulo: Agronômica Ceres; 2006.

Marengo RA, Lopes NF. Fisiologia vegetal. 3<sup>a</sup> ed. Viçosa: Editora UFV; 2009.

Martin-Prével P. Bananier. In: Martin-Prével P, Gagnard J, Gautier P. Editores. L'analyse végétale dans le contrôle de l'alimentation des plantes tempérées et tropicales. Paris: Tec&Doc; 1984. p.715-51.

Mengel K, Kirkby EA. Principles of plant nutrition. 5<sup>th</sup> ed. Dordrecht: Kluwer Academic; 2001.

Meurer EJ. Potássio. In: Manlio SF. Editor. Nutrição mineral de plantas. Viçosa: Sociedade Brasileira de Ciência do Solo; 2006. p.282-298.

Montagut G, Martin-Prével P. Besoins en engrais des bananeraies antillaises. Fruits. Paris. 1965; 20:265-273.

Monteiro FA, Ramos AKB, Carvalho DD, Abreu JBR, Daiub JAS, Silva JEP, Natale W. Cultivo de *Brachiaria brizantha* stapf. Cv. Marandu em solução nutritiva com omissões de macronutrientes. Sci. Agric. Piracicaba. 1995; 52:135-141.

Novais RF, Smyth TJ, Nunes FN. VII – Fósforo. In: Novais RF, Alvarez VH, Barros NF, Fontes RL, Cantarutti RB, Neves JCL. editores. Fertilidade do solo. Viçosa: Sociedade Brasileira de Ciência do Solo; 2007. p.92-120.

Paiva EAS, Sampaio RA, Martinez HEP. Composition and quality of tomato fruit cultivated in nutrient solutions containing different calcium concentration. Journal of plant nutri. Philadelphia. 1998; 21:2653-2661.

Paiva R, Oliveira LM. Fisiologia e produção vegetal. Lavras: Editora UFLA; 2006. 104.

Perrier X, Bakry F, Carreel F, Jenny C, Horry JP, Lebot V, Hippolyte I. Combining biological approaches to shed light on the evolution of edible bananas. Ethnobot. research and applications. Fort Worth. 2009; 7:199-216.

Pestana M, Varennes A, Faria EA. Diagnosis and correction of iron chlorosis in fruit trees: a review. Food Agric. Environ. 2003; 1:46-51.

Prado RM. 500 perguntas e respostas sobre nutrição de plantas. 1. ed. Jaboticabal: FCAV/GENPLANT; 2009.

Sena-Júnior DG, Pinto FAC, Gomide LA, Teixeira MM. Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por *Spodoptera frugiperda*. Rev. Bras. Eng. Agríc. Ambiental; 2003. 7:359-366.

Siddiqi MY, Glass ADM. Utilization index: a modified approach to the estimation and comparison of nutrient efficiency in plants. Journal of plant nutr. Monticello. 1981; 4:289-302.

Silva JTA, Carvalho JG. Avaliação nutricional de bananeira Prata-Anã (AAB), sob irrigação no semi-árido do norte de Minas Gerais, pelo método Dris. Ci. Agrotecnologia, Lavras. 2005; 29:731-739.

Soares FAL, Gheyi HR, Oliveira FHT, Fernandes PD, Alves NA, Silva FV. Acúmulo, exportação e restituição de nutrientes pelas bananeiras “Prata Anã” e “Grand Naine”. Ci Rural. 2008; 38:2054-2058.

Teixeira LAJ, Spironello A, Quaggio JA, Furlani PR. Banana. In: Raij B, Cantarella H, Quaggio JÁ, FUrlani AMC. Editores. Recomendações de adubação e calagem para o Estado de São Paulo. Campinas: Fundação IAC; 1997. p.131–132. (Boletim, 100).

Tourian OK, Padilha FRR. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. Eng. agríc. Jaboticabal. 2008; 28:759-769.

Turner DW, Barkus, B. Loss of mineral nutrients from banana pseudostems after harvest. Trop. Agriculture. 1973; 50:229-233.

Vale DW, Prado RM, Avalhães CC, Hojo RH. Omissão de macronutrientes na nutrição e no crescimento da cana-de-açúcar cultivada em solução nutritiva. Rev. bras. ciênc. Agrár. Recife. 2011; 6:189-196.

Varella CAA, Pinto FAC, Queiroz DM, Sena-Júnior DG. Determinação da cobertura do solo por análise de imagens e redes neurais. Ver. Bras. Eng. Agríc. Ambiental. 2002; 6:225-229.

Venkatesh YV, Raja S. On the classification of multispectral satellite images using the multilayer perceptron. Pattern Recognition. 2003; 36:2161-2175.

Venturini MT, Santos LR, Oliveira EJ. Development of a diagramatic scale for the evaluation of postharvest physiological deterioration in cassava roots. Pesq. Agropec. Bras. Brasília. 2015; 50:658-668. Doi: 10.1590/S0100-204X2015000800004

Baranauskas JA. Extração automática de conhecimento por múltiplos indutores [tese]. São Paulo: Instituto de Ciências Matemáticas e de Computação (USP); 2000.

Bataglia OC, Furlani AMC, Teixeira JPF, Furlani PR, Gallo JR. Métodos de análise química de plantas. Campinas: Instituto Agrônômico; 1983. (Boletim Técnico, 78).

Borges AL, Oliveira e Silva S, Caldas RC, Ledo CAS. Teores foliares de nutrientes em genótipos de bananeira. Jaboticabal: Rev. Bras. Frutic. 2006; 28:314-318.

Borges AL. Interação entre nutrientes em bananeira. Cruz das Almas: Embrapa CNPMF; 2004. (Banana em Foco, 55)

Camara G, Souza RCM, Freitas UM, Garrido J. SPRING: Integrating remote sensing and GIS by objectoriented data modeling. Computers & Graphics: New York; 1996. 20:395-403.

Chagas CS, Vieira CAO, Fernandes-Filho EI, Júnior WC. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. Eng. Agríc. Ambiental. 2009; 13:319-327.

Cunningham S, Denize P. Dept. of computer science [internet]. New Zeland: Universit of Waikato; 1995 [acesso em 20 de ago de 2015]. Disponível em: <http://www.cs.waikato.ac.nz/ml/publications.html>.

Da Silva JTA, Pacheco DD, Costa EL. Atributos químicos e físicos de solos cultivados com bananeira ‘Prata-Anã’, em três níveis de produtividade, no norte de Minas Gerais. Jaboticabal: Rev. Bras. Frutic. 2007; 29:102-106.

Efron B, Gong G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. Washington: The American Statistician; 1983. 37:36-48.

Efron B, Tibshirani RJ. An Introduction to the Bootstrap. New York: Chapman & Hall; 1993.

Genú PJC. Influência da idade da planta e época de amostragem de material do solo nos teores de K, Ca, Mg em três bananais Prata [dissertação]. Lavras: UFLA (ESAL); 1976.

## **CONSIDERAÇÕES FINAIS**

A utilização da técnica de Redes Neurais Artificiais e o Processamento Digital de Imagens como ferramentas de avaliação da deficiência nutricional de plantas de banana demonstraram-se promissora, necessitando de maiores pesquisas para refinar a técnica e melhorar seu funcionamento.

## REFERÊNCIAS GERAIS

Almeida TBF, Prado RM, Flores RA, Politi LC, Barbosa JC. Avaliação nutricional do almeirão em soluções nutritivas suprimidas de macronutrientes. *Scien. agrár. Paranaensis*. 2013; 12:211-220.

Azeredo JA, Genú PYC, Aquino ARL, Campelo-Júnior JH, Rodriguez APM. Nutrição mineral e adubação da bananeira. In: Haag, HP Coord. Nutrição mineral e adubação de frutíferas tropicais do Brasil. 1ª ed. Campinas: Fundação Cargill; 1986. p.59-102.

Bagheri N, Ahmadi H, Alavipanah SK, Omid M. Multispectral remote sensing for site-specific nitrogen fertilizer management. *Pesq. Agropec. Bras. Brasília*. 2013; 48:1394-1401. doi: 10.1590/S0100-204X2013001000011

Baranauskas JA. Extração automática de conhecimento por múltiplos indutores [tese]. São Paulo: Instituto de Ciências Matemáticas e de Computação (USP); 2000.

Bataglia OC, Furlani AMC, Teixeira JPF, Furlani PR, Gallo JR. Métodos de análise química de plantas. Campinas: Instituto Agrônomo; 1983. (Boletim Técnico, 78)

Borges AL, Oliveira AMG, Souza, LS. Solos, nutrição e adubação. In: Alves EJ. editor. A cultura da banana: aspectos técnicos, socioeconômicos e agroindustriais. Brasília: Embrapa; 1999. p.197-260.

Borges AL. Interação entre nutrientes em bananeira. Cruz das Almas: Embrapa CNPMF; 2004. (Banana em Foco, 55).

Braz CF, Polivanov H, Chagas, CS, Carvalho-Júnior W, Barroso EV, Guerra AJT, Calderano SB. Artificial neural networks applied for soil class prediction in mountainous landscape of the serra do mar. *R. bras. ci. solo*. 2014; 38:1681-1693.

Camara G, Souza RCM, Freitas UM, Garrido J. SPRING: Integrating remote sensing and GIS by objectoriented data modeling. *Computers & Graphics: New York*; 1996. 20:395-403.

Cosme FCC. Árvores de decisão [internet]. Local: instituto; 2002 [acesso em 10 de jul de 2015]. Disponível em: <http://pt.scribd.com/doc/218178007/Arvores-de-decisao-doc>.

Cunningham S, Denize P. Dept. of computer science [internet]. New Zeland: Universit of Waikato; 1995 [acesso em 20 de ago de 2015]. Disponível em: <http://www.cs.waikato.ac.nz/ml/publications.html>.

Efron B, Gong G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. *Washington: The American Statistician*; 1983. 37:36-48.

Efron B, Tibshirani RJ. An Introduction to the Bootstrap. New York: Chapman & Hall; 1993.

FAO. Statistics Division. Food and Agriculture commodities production [internet]. Roma: Fao; 2013 [acesso em 06 de fev de 2016]. Disponível em: [http://faostat3.fao.org/browse/rankings/countries\\_by\\_commodity/S](http://faostat3.fao.org/browse/rankings/countries_by_commodity/S).

Fleiss JL. Statistical methods for rates and proportions, 2nd ed. New York: John Wiley & Sons, 1981.

Fonseca JA, Meurer EJ. Inibição da absorção de magnésio pelo potássio em plântulas de milho em solução nutritiva. Rev. bras. ciên. Solo. Campinas. 1997; 21:47-50.

Furlani PR, Silveira LCP, Bolonhezi D, Faquin V. Cultivo hidropônico de plantas. Campinas: IAC; 1999. (Boletim Técnico, 180).

Galen RS, Gambino SR. Beyond normality: The predictive value and efficiency of medical diagnosis. New York: J. Wiley & Sons; 1975.

Gomes JA. Absorção de nutrientes pela banana, cultivar Prata (*Musa* AAB, subgrupo Prata) em diferentes estádios de desenvolvimento [tese]. Piracicaba: ESALQ; 1988.

Haag HP, Minami K. Nutrição mineral de hortaliças: LXXV. Absorção de nutrientes pela cultura de almeirão. Anais da Escola Superior de Agricultura Luiz de Queiroz, 1998; 45:597-603.

Hawksford M, Horst W, Kichey T, Lambers H, Schjoerring J, Moller IS, White P. Functions of macronutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.135-189.

Haykin S. Neural networks and learning machines. 3rd ed. New York: Prentice Hall; 2009.

Haykin S. Neural Networks: A Comprehensive Foundation. New York: MacMillan, 1999.

Haykin S. Redes neurais: princípios e prática. Porto Alegre: Bookman; 2001.

Hoagland DR, Arnon DI. The water culture method for growing plants without soils. Berkeley: California Agricultural Experimental Station; 1950.

IBGE. Base de dados agregados [internet]. Brasília: instituto Brasileiro de Geografia e Estatística; 2016 [acesso em 06 fev de 2016]. Disponível em: <http://www.sidra.ibge.gov.br/bda/prevsaf/default.asp>.

Johnson RA, Wichern DW. Applied Multivariate Statistical Analysis, 5 ed. New Jersey: Prentice-Hall; 2002.

Kirkby E. Introduction, definition and classification of nutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.3-5.

Lahav E. Banana nutrition. In: Gowen S. ed. Bananas and plantains. London, Chapman & Hall; 1995. p.258-316.

Malavolta E. Elementos de nutrição mineral de plantas. São Paulo: Agronômica Ceres; 1980.

Malavolta EA, Manual de nutrição mineral de plantas. São Paulo: Agronômica Ceres; 2006.

Marengo RA, Lopes NF. Fisiologia vegetal. 3<sup>a</sup> ed. Viçosa: Editora UFV; 2009.

Martin-Prével P. Bananier. In: Martin-Prével P, Gagnard J, Gautier P. Editores. L'analyse végétale dans le contrôle de l'alimentation des plantes tempérées et tropicales. Paris: Tec&Doc; 1984. p.715-51.

Mengel K, Kirkby EA. Principles of plant nutrition. 5<sup>th</sup> ed. Dordrecht: Kluwer Academic; 2001.

Meurer EJ. Potássio. In: Manlio SF. Editor. Nutrição mineral de plantas. Viçosa: Sociedade Brasileira de Ciência do Solo; 2006. p.282-298.

Montagut G, Martin-Prével P. Besoins en engrais des bananeraies antillaises. Fruits. Paris. 1965; 20:265-273.

Monteiro FA, Ramos AKB, Carvalho DD, Abreu JBR, Daiub JAS, Silva JEP, Natale W. Cultivo de *Brachiaria brizantha* stapf. Cv. Marandu em solução nutritiva com omissões de macronutrientes. Sci. Agric. Piracicaba. 1995; 52:135-141.

Novais RF, Smyth TJ, Nunes FN. VII – Fósforo. In: Novais RF, Alvarez VH, Barros NF, Fontes RL, Cantarutti RB, Neves JCL. editores. Fertilidade do solo. Viçosa: Sociedade Brasileira de Ciência do Solo; 2007. p.92-120.

Paiva EAS, Sampaio RA, Martinez HEP. Composition and quality of tomato fruit cultivated in nutrient solutions containing different calcium concentration. Journal of plant nutri. Philadelphia. 1998; 21:2653-2661.

Paiva R, Oliveira LM. Fisiologia e produção vegetal. Lavras: Editora UFLA; 2006. 104.

Perrier X, Bakry F, Carreel F, Jenny C, Horry JP, Lebot V, Hippolyte I. Combining biological approaches to shed light on the evolution of edible bananas. Ethnobot. research and applications. Fort Worth. 2009; 7:199-216.

Pestana M, Varennes A, Faria EA. Diagnosis and correction of iron chlorosis in fruit trees: a review. Food Agric. Environ. 2003; 1:46-51.

Prado RM. 500 perguntas e respostas sobre nutrição de plantas. 1. ed. Jaboticabal: FCAV/GENPLANT; 2009.

Sena-Júnior DG, Pinto FAC, Gomide LA, Teixeira MM. Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por *Spodoptera frugiperda*. Rev. Bras. Eng. Agríc. Ambiental; 2003. 7:359-366.

Siddiqi MY, Glass ADM. Utilization index: a modified approach to the estimation and comparison of nutrient efficiency in plants. Journal of plant nutr. Monticello. 1981; 4:289-302.

Silva JTA, Carvalho JG. Avaliação nutricional de bananeira Prata-Anã (AAB), sob irrigação no semi-árido do norte de Minas Gerais, pelo método Dris. Ci. Agrotecnologia, Lavras. 2005; 29:731-739.



Soares FAL, Gheyi HR, Oliveira FHT, Fernandes PD, Alves NA, Silva FV. Acúmulo, exportação e restituição de nutrientes pelas bananeiras “Prata Anã” e “Grand Naine”. Ci Rural. 2008; 38:2054-2058.

Teixeira LAJ, Spironello A, Quaggio JA, Furlani PR. Banana. In: Raij B, Cantarella H, Quaggio JÁ, FURLANI AMC. Editores. Recomendações de adubação e calagem para o Estado de São Paulo. Campinas: Fundação IAC; 1997. p.131-132. (Boletim, 100).

Tourian OK, Padilha FRR. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. Eng. agríc. Jaboticabal. 2008; 28:759-769.

Turner DW, Barkus, B. Loss of mineral nutrients from banana pseudostems after harvest. Trop. Agriculture. 1973; 50:229-233.

Vale DW, Prado RM, Avalhães CC, Hojo RH. Omissão de macronutrientes na nutrição e no crescimento da cana-de-açúcar cultivada em solução nutritiva. Rev. bras. ciênc. Agrár. Recife. 2011; 6:189-196.

Varella CAA, Pinto FAC, Queiroz DM, Sena-Júnior DG. Determinação da cobertura do solo por análise de imagens e redes neurais. Ver. Bras. Eng. Agríc. Ambiental. 2002; 6:225-229.

Venkatesh YV, Raja S. On the classification of multispectral satellite images using the multilayer perceptron. Pattern Recognition. 2003; 36:2161-2175.

Venturini MT, Santos LR, Oliveira EJ. Development of a diagramatic scale for the evaluation of postharvest physiological deterioration in cassava roots. Pesq. Agropec. Bras. Brasília. 2015; 50:658-668. Doi: 10.1590/S0100-204X2015000800004

Baranauskas JA. Extração automática de conhecimento por múltiplos indutores [tese]. São Paulo: Instituto de Ciências Matemáticas e de Computação (USP); 2000.

Bataglia OC, Furlani AMC, Teixeira JPF, Furlani PR, Gallo JR. Métodos de análise química de plantas. Campinas: Instituto Agrônômico; 1983. (Boletim Técnico, 78).

Borges AL, Oliveira e Silva S, Caldas RC, Ledo CAS. Teores foliares de nutrientes em genótipos de bananeira. Jaboticabal: Rev. Bras. Frutic. 2006; 28:314-318.

Borges AL. Interação entre nutrientes em bananeira. Cruz das Almas: Embrapa CNPMF; 2004. (Banana em Foco, 55)

Camara G, Souza RCM, Freitas UM, Garrido J. SPRING: Integrating remote sensing and GIS by objectoriented data modeling. Computers & Graphics: New York; 1996. 20:395-403.

Chagas CS, Vieira CAO, Fernandes-Filho EI, Júnior WC. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. Eng. Agríc. Ambiental. 2009; 13:319-327.

Cunningham S, Denize P. Dept. of computer science [internet]. New Zeland: Universit of Waikato; 1995 [acesso em 20 de ago de 2015]. Disponível em: <http://www.cs.waikato.ac.nz/ml/publications.html>.

Da Silva JTA, Pacheco DD, Costa EL. Atributos químicos e físicos de solos cultivados com bananeira 'Prata-Anã', em três níveis de produtividade, no norte de Minas Gerais. Jaboticabal: Rev. Bras. Frutic. 2007; 29:102-106.

Efron B, Gong G. A leisurely Look at the bootstrap, the jackknife, and crossvalidation. Washington: The American Statistician; 1983. 37:36-48.

Efron B, Tibshirani RJ. An Introduction to the Bootstrap. New York: Chapman & Hall; 1993.

Genú PJC. Influência da idade da planta e época de amostragem de material do solo nos teores de K, Ca, Mg em três bananeiras Prata [dissertação]. Lavras: UFLA (ESAL); 1976.

Gomes FT, Borges AC, Neves JCL, Fontes PCR. Influence of limestone rates with different calcium:magnesium ratios on shoot dry matter yield and mineral composition of alfalfa. Pesq. Agrop. Bras. 2002; 37:1779-1786.

Gomes JA. Absorção de nutrientes pela bananeira cv. Prata (*Musa* AAB, subgrupo prata) em diferentes estádios de desenvolvimento [dissertação]. Piracicaba: ESALQ; 1988.

Hawksford M, Horst W, Kichey T, Lambers H, Schjoerring J, Moller IS, White P. Functions of macronutrients. In: Marschner P. ed. Marschner's mineral nutrition of higher plants. 3<sup>rd</sup> ed. Elsevier; 2012. p.135-189.

Haykin S. Neural Networks: A Comprehensive Foundation. New York: MacMillan, 1999.

Johnson RA, Wichern DW. Applied Multivariate Statistical Analysis, 5 ed. New Jersey: Prentice-Hall; 2002.

Khatchatourian O, Padilha FRR. Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. Jaboticabal: Eng. Agríc. 2008; 28:759-769.

Lopez MA, Espinosa MJ. Manual de nutrición y fertilización del banano. Quito: INPOFOS; 1995.

Malavolta E. ABC da Adubação. 4<sup>a</sup> edição. São Paulo: Editora Agronomia Ceres; 1979.

Martin-Prével P. Bananier. In: Martin-Prével P, Gagnard J, Gautier P. Editores. L'analyse végétale dans le contrôle de l'alimentation des plantes tempérées et tropicales. Paris: Tec&Doc; 1984. p.715-51.

Mengel K, Kirkby EA. Principles of plant nutrition. Principles of plant nutrition. 4<sup>th</sup> ed. Bern: International Potash Institute; 1987.

Moreira RS. Banana: teoria e prática de cultivo. 2.ed. São Paulo: Fundação Cargill, 1999. CD-ROM.

Moreira RS. Banana: teoria e prática de cultivo. Campinas: Fundação Cargill; 1987.

Munson RD, Nelson WL. Principles and practices in plant analysis. In: Walsh LM, Beaton JD. eds. Soil testing and plant analysis. Madison: Soil Science Society of America; 1973. p.223-248.

Natale W, Prado RM, Rozane DE, Romualdo LM. Efeitos da calagem na fertilidade do solo e na nutrição e produtividade da goiabeira. R. bras. ci. Solo. 2007; 31:1475-1485.

Nomura ES, Teixeira LAJ, Boaretto RM, Garcia VA, Fuzitani EJ, Damatto-Júnior ER, Saes LA, Mattos-Júnior DM. Aplicação de boro em bananeira. Jaboticabal. Rev. Bras. Fruticultura. 2011; 33:608-617.

Oliveira FP, Fernandes-Filho EI, Soares VP, Souza AL. Mapeamento de fragmentos florestais com monodominância de Aroeira a partir da classificação supervisionada de imagens rapideye. R. Árvore. 2013; 37:151-161.

Quaggio JA, Raij B, Piza-Jr CT. Frutíferas. In: Raij B, Quaggio AJ, Cantarella H, Furlani AMC. Org. Recomendações de adubação e calagem para o Estado de São Paulo. 2.ed. Campinas: Instituto Agrônomo; 1997. p121-153. (Boletim Técnico, 100)

Raij B, Andrade JC, Cantarella H, Quaggio JA. Análise química para avaliação da fertilidade de solos tropicais. Campinas: Instituto Agrônomo; 2001.

Sena-Júnior DG, Pinto FAC, Gomide LA, Teixeira MM. Avaliação de métodos automáticos de limiarização para imagens de plantas de milho atacadas por *Spodoptera frugiperda*. Rev. Bras. Eng. Agríc. Ambiental; 2003. 7:359-366.

Silva EF, Moitinho MR, Teixeira DB, Pereira GT, Scala-Júnior N. emissão de CO<sub>2</sub> do solo associada à calagem em área de conversão de laranja para cana-de-áçúcar. Jaboticabal: Eng. Agríc. 2014; 34:885-898.

Silva JTA, Carvalho JG. Avaliação nutricional de bananeira Prata-Anã (AAB), sob irrigação no semi-árido do norte de Minas Gerais, pelo método Dris. Lavras: Ciênc. Agrotec. 2005; 29:731-739.

Silva JTA, Silva IP, Moura Neto A, Costa ED. Aplicação de potássio, magnésio e calcário em mudas de bananeira Prata-Anã (AAB). Jaboticabal: R. Bras. Frutic. 2008; 30:782-786.

Silva SHMG. Processamento digital de imagens para identificação da sigatoka negra em bananais utilizando análise de componentes principais e redes neurais artificiais [tese]. Botucatu: UNESP; 2008. 83p.

Teixeira LAJ, Natale W, Bettiol-Neto JE, Martins ALM. Nitrogênio e potássio em bananeira via fertirrigação e adubação convencional-atributos químicos do solo. Rev. Bras. Fruticultura. 2007b; 29:143-152.

Teixeira LAJ, Raij B, Bettiol-Neto JE. Estimativa das necessidades nutricionais de bananeiras do subgrupo Cavendish cultivadas no Estado de São Paulo. Rev. Bras. Fruticultura. 2008; 30:540-545.

Teixeira LAJ, Spironello A, Quaggio JA, Furlani PR. Banana. In: Raij B, Cantarella H, Quaggio JA, Furlani AMC. Editores. Recomendações de adubação e calagem para o Estado de São Paulo. Campinas: Fundação IAC; 1997. p.131–132. (Boletim, 100).

Teixeira LAJ, Spironello A, Quaggio JÁ, Furlani PR. Banana. In: Raij B. Org. Recomendações de adubação e calagem para o Estado de São Paulo. 2ed.Campinas: Instituto Agrônômico de Campinas. 2007a; p.131-132.

Wichmann W. World fertilizer use manual. Paris: IFA; 1992.